



TESIS - SS14 2501

MODEL PERAMALAN HIBRIDA UNTUK PREDIKSI JUMLAH PENUMPANG UDARA DAN VOLUME KARGO DI INDONESIA

RATNA SULISTYOWATI
NRP. 06211650017006

DOSEN PEMBIMBING
Dr. Suhartono, M.Sc
Dr.rer.pol. Heri Kuswanto, M.Si

PROGRAM PASCASARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



TESIS - SS14 2501

MODEL PERAMALAN HIBRIDA UNTUK PREDIKSI JUMLAH PENUMPANG UDARA DAN VOLUME KARGO DI INDONESIA

RATNA SULISTYOWATI
NRP. 06211650017006

DOSEN PEMBIMBING

Dr. Suhartono, M.Sc
Dr.rer.pol. Heri Kuswanto, M.Si

PROGRAM PASCASARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



THESIS - SS14 2501

HYBRID FORECASTING MODEL TO PREDICT NUMBER OF AIR PASSENGERS AND CARGO VOLUME IN INDONESIA

RATNA SULISTYOWATI
NRP. 06211650017006

SUPERVISOR

Dr. Suhartono, M.Sc
Dr.rer.pol. Heri Kuswanto, M.Si

PROGRAM OF POSTGRADUATE
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018

MODEL PERAMALAN HIBRIDA UNTUK PREDIKSI JUMLAH PENUMPANG UDARA DAN VOLUME KARGO DI INDONESIA

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh:

RATNA SULISTYOWATI
NRP. 06211650017006

Tanggal Ujian : 16 Januari 2018
Periode Wisuda : Maret 2018

Disetujui Oleh:



1. Dr. Suhartono, M.Sc
NIP.19710929 199512 1 001

(Pembimbing I)



2. Dr. rer.pol. Heri Kuswanto, M.Si
NIP.198203262003121 004

(Pembimbing II)



3. Dr. Ir. Setiawan, MS
NIP.19601030 198701 1 001

(Penguji)




4. Dr. Erni Tri Astuti M. Math
NIP.196710221990032002

(Penguji)



Dekan
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember


Prof. Dr. Basuki Widodo, M.Sc.
NIP.19650605 198903 1 002

MODEL PERAMALAN HIBRIDA UNTUK PREDIKSI JUMLAH PENUMPANG UDARA DAN VOLUME KARGO DI INDONESIA

Nama Mahasiswa : Ratna Sulistyowati
NRP : 06211650017006
Pembimbing : Dr. Suhartono, M.Sc
: Dr. rer. pol. Heri Kuswanto, M.Si

ABSTRAK

Peramalan untuk penumpang udara dan kargo memiliki pengaruh besar terhadap *master plan* pengembangan infrastruktur bandara dan investasi oleh maskapai penerbangan sipil. Penelitian ini bertujuan untuk memperoleh nilai ramalan yang akurat dari data penumpang dan kargo di tiga bandara internasional Indonesia yaitu Bandara Internasional Soekarno Hatta, Bandara Internasional I Gusti Ngurah Rai, dan Bandara Internasional Juanda. Ketiga bandara internasional tersebut mempunyai kontribusi terbesar terhadap jumlah penumpang udara dan volume kargo di Indonesia. Penelitian ini menggunakan metode peramalan hibrida yang menggabungkan dua model linier dan nonlinier melalui dua tahapan pemodelan, sehingga melalui metode hibrida diharapkan dapat menghasilkan ramalan yang lebih akurat. Tahap pertama adalah melakukan pemodelan linier yaitu dengan model *time series regression* (TSR) dan *Autoregressive Integrated Moving Average with Exogenous Factor* (ARIMAX). Selanjutnya tahap kedua melakukan pemodelan hibrida yang bekerja menggunakan input residual dari model linier yang dimodelkan dengan metode yang lebih kompleks seperti pendekatan *machine learning* yaitu *Neural Network* (NN) dan *Support Vector Regression* (SVR), untuk menangkap pola nonlinier. Penelitian ini membandingkan akurasi hasil peramalan empat model peramalan hibrida antara lain hibrida TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa pemodelan hibrida menggunakan NN (ARIMAX-NN dan TSR-NN) pada data *testing* menghasilkan peramalan yang lebih baik dibandingkan dengan model hibrida menggunakan SVR (TSR-SVR dan ARIMAX-SVR).

Kata kunci: Penumpang Udara, Kargo, Regresi *time series*, ARIMAX, *Neural Network*, *Support Vector Regression*, Hibrida.

HYBRID FORECASTING MODEL TO PREDICT NUMBER OF AIR PASSENGERS AND CARGO VOLUME IN INDONESIA

Name : Ratna Sulistyowati
NRP : 06211650017006
Supervisors : Dr. Suhartono, M.Sc
: Dr.rer.pol. Heri Kuswanto, M.Si

ABSTRACT

Forecasting of air passengers and cargo have a major influence on the master plan of the airport infrastructure development and investment by the civil airline. This research aims to obtain the most accurate predictive value of the air passengers and cargo at three international airports Indonesia, namely, Soekarno Hatta Airport, I Gusti Ngurah Rai Airport, and Juanda Airport. Those international airports are the three largest contributors to the number of air passengers and cargo volumes in Indonesia. This research uses a hybrid forecasting method that combines linear models and nonlinear models. The combination of two models linear and nonlinear is able to obtain accurate predictions. The first phase is linear modeling with time series regression model (TSR) and Autoregressive Integrated Moving Average with Exogenous Factor (ARIMAX). In the second phase, hybrid modeling works using the error of linear models modeled by more complex machine learning methods such as Neural Network (NN) and Support Vector Regression (SVR), to capture the nonlinear patterns. This paper compares the accuracy of forecasting the four hybrid models include TSR-NN, TSR-SVR, ARIMAX-NN, and ARIMAX-SVR based on the Mean Absolute Percentage Error (MAPE). The results show that modeling hybrid using NN, i.e. ARIMAX-NN and TSR-NN have better performance prediction than modeling hybrid using SVR, i.e. TSR-SVR and ARIMAX-SVR.

Kata kunci: Air passenger, Cargo, Time Series Regression, ARIMAX, Neural Networks, Support Vector Regression, Hybrid.

KATA PENGANTAR

Alhamdulillah serta puji syukur penulis panjatkan ke hadirat Allah SWT atas berkah hidayahNya sehingga penulis dapat menyelesaikan tesis dengan judul:

**“MODEL PERAMALAN HIBRIDA UNTUK PREDIKSI JUMLAH
PENUMPANG UDARA DAN VOLUME KARGO DI INDONESIA”**

Keberhasilan penyusunan tesis ini berkat bantuan, bimbingan dan dukungan dari berbagai pihak. Untuk itu, penulis ingin mengucapkan terima kasih kepada:

1. Badan Pusat Statistik (BPS) atas kesempatan serta dukungan finansial berupa beasiswa kepada penulis untuk dapat melanjutkan studi S2 di ITS.
2. Bapak Dr. Suhartono, M.Sc selaku Kepala Departemen Statistika dan Bapak Dr. rer.pol. Heri Kuswanto, M.Si selaku Ketua Program Studi Pascasarjana, sekaligus sebagai dosen pembimbing yang telah meluangkan waktu, bimbingan, serta ilmu yang berguna dalam penyusunan tesis ini.
3. Bapak Dr. Ir. Setiawan, M.S dan Ibu Dr. Erni Tri Astuti M. Math, selaku dosen penguji yang telah memberikan saran dan masukan atas penulisan tesis ini.
4. Ibu Dr. Santi Wulan Purnami, S.Si, M.Si, selaku dosen wali, seluruh Bapak/Ibu dosen pengajar yang telah memberikan ilmu dan pengalaman yang bermanfaat kepada penulis, serta segenap pegawai dan keluarga besar Departemen Statistika ITS atas segala bantuannya.
5. Suami tercinta “Eko Siswahto” serta buah hati tersayang “Aqlan Rafa Ibrahim” sebagai sumber motivasi dalam perjalanan hidup penulis. Senyum, tawa, dukungan, pengertian dan kasih sayang yang selalu menjadi semangat baru buat penulis dalam penyelesaian tesis ini.
6. Ibunda tercinta Dra. Hadriani, Ayahanda Alm. Drs Bambang Judo Soebandono, serta seluruh keluarga besar Soebandono dan Soetrisno, atas segala kasih sayang, harapan, nasehat, serta doa yang tak pernah putus untuk kesuksesan dan kebahagiaan penulis.
7. Teman-teman seperjuangan ITS-BPS Batch 10: Sartika, Reni, Ratih, Imra, Mike, Prih, Umam, Fendi, Rafael, Suprpto, Anik, Sony, Taufik, Ibu Sarni dan

Ibu Arifatus atas dukungan, semangat, kekompakan, keceriaan dan kebersamaan selama menjalani pendidikan di ITS.

8. Teman-teman reguler angkatan 2016, Indah, Bahagiati, Zahroh, Meranggi, Sari, Gazali, dan Hasan, serta semua pihak yang tidak bisa disebutkan satu persatu.

Penulis menyadari bahwa tesis ini masih jauh dari sempurna. Oleh karena itu, kritik maupun saran yang bersifat membangun diharapkan penulis demi perbaikan tesis ini. Akhirnya, semoga tesis ini dapat memberikan banyak manfaat bagi semua pihak.

Surabaya, Januari 2018

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	ii
ABSTRAK	iii
ABSTRACT	v
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN	xxi
 BAB 1 PENDAHULUAN	 1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Penelitian	6
 BAB 2 TINJAUAN PUSTAKA	 7
2.1 Sejarah Penerbangan di Indonesia	7
2.2 Perkembangan Transportasi Udara di Indonesia	8
2.3 Analisis <i>Time Series</i>	9
2.4 Model <i>Time Series Regression</i> (TSR)	10
2.5 Model ARIMA	11
2.5.1 Identifikasi Model	12
2.5.2 Estimasi dan Uji Signifikansi Parameter	15
2.5.3 Cek Diagnosa Model	17
2.5.4 Peramalan ARIMA	18
2.6 Model <i>Autoregressive Integrated Moving Average with Exogenous Factor</i> (ARIMAX)	19
2.7 Deteksi <i>Outlier</i>	20
2.7.1 <i>Additive Outlier</i> (AO)	21
2.7.2 <i>Innovational Outlier</i> (IO)	21

2.7.3	<i>Level Shift (LS)</i>	22
2.7.4	<i>Temporary Change</i>	22
2.8	Uji Nonlinieritas pada Data <i>Time Series</i>	22
2.9	Model <i>Neural Network</i> (NN)	23
2.9.1	<i>Feed Forward Neural Networks</i>	24
2.9.2	<i>Algoritma Back-Propagation</i>	26
2.10	Model <i>Support Vector Regression</i> (SVR)	28
2.11	Model Peramalan Hibrida	31
2.12	Kriteria Pemilihan Model Terbaik	33
BAB 3	METODOLOGI PENELITIAN	35
3.1	Sumber Data	35
3.2	Variabel Penelitian	35
3.3	Struktur Data	37
3.4	Tahapan Penelitian	39
BAB 4	HASIL DAN PEMBAHASAN	45
4.1	Karakteristik Data Penumpang dan Kargo	45
4.1.1	Karakteristik Data di Bandara Internasional Soekarno Hatta	47
4.1.2	Karakteristik Data di Bandara Internasional I Gusti Ngurah Rai	49
4.1.3	Karakteristik Data di Bandara Internasional Juanda	52
4.2	Pemodelan Bandara Internasional Soekarno Hatta	54
4.2.1	Pemodelan <i>Time Series Regression</i> (TSR)	54
4.2.2	Pemodelan ARIMAX	58
4.2.3	Hasil Pengujian Nonlinieritas	62
4.2.4	Pemodelan Hibrida TSR-NN	63
4.2.5	Pemodelan Hibrida ARIMAX-NN	67
4.2.6	Pemodelan Hibrida TSR-SVR	70
4.2.7	Pemodelan Hibrida ARIMAX-SVR	72
4.2.8	Perbandingan Hasil Model Peramalan	74
4.2.9	Hasil Ramalan Hingga Tahun 2018 di Bandara Soekarno Hatta	78
4.3	Pemodelan Bandara Internasional I Gusti Ngurah Rai	81

4.3.1	Pemodelan <i>Time Series Regression</i> (TSR)	81
4.3.2	Pemodelan ARIMAX	83
4.3.3	Hasil Pengujian Nonlinieritas	85
4.3.4	Pemodelan Hibrida TSR-NN	86
4.3.5	Pemodelan Hibrida ARIMAX-NN	87
4.3.6	Pemodelan Hibrida TSR-SVR	88
4.3.7	Pemodelan Hibrida ARIMAX-SVR	89
4.3.8	Perbandingan Hasil Model Peramalan	90
4.3.9	Hasil Ramalan Hingga Tahun 2018 di Bandara I Gusti Ngurah Rai	93
4.4	Pemodelan Bandara Internasional Juanda	96
4.4.1	Pemodelan <i>Time Series Regression</i> (TSR)	96
4.4.2	Pemodelan ARIMAX	98
4.4.3	Hasil Pengujian Nonlinieritas	100
4.4.4	Pemodelan Hibrida TSR-NN	101
4.3.5	Pemodelan Hibrida ARIMAX-NN	102
4.3.6	Pemodelan Hibrida TSR-SVR	103
4.3.7	Pemodelan Hibrida ARIMAX-SVR	104
4.3.8	Perbandingan Hasil Model Peramalan	105
4.3.9	Hasil Ramalan Hingga Tahun 2018 di Bandara Juanda	108
4.5	Prediksi Kumulatif Penumpang Udara dan Kargo Hingga Tahun 2018	111
4.6	Ringkasan Hasil Analisis Tiga Bandara Internasional di Indonesia	112
BAB 5	KESIMPULAN DAN SARAN	115
5.1	Kesimpulan	115
5.2	Saran	116
	DAFTAR PUSTAKA	117
	LAMPIRAN	123
	BIOGRAFI PENULIS	189

DAFTAR TABEL

	Halaman
Tabel 2.1 Kapasitas Penumpang dan Kargo serta Realisasinya Tahun 2016..	9
Tabel 2.2 Nilai Transformasi Box Cox	13
Tabel 2.3 Pola Teoritik ACF dan PACF dari Proses Stasioner	15
Tabel 2.4 Varians Parameter ARIMA	17
Tabel 3.1. Variabel Respon dalam Penelitian	36
Tabel 3.2. Tanggal Hari Raya Idul Fitri Periode 2001-2017	37
Tabel 3.3. Struktur Data Bandara Soekarno Hatta	38
Tabel 4.1. Statistika Deskriptif Data Penumpang dan Kargo Bandara Soekarno Hatta	49
Tabel 4.2 Statistika Deskriptif Data Penumpang dan Kargo Bandara I Gusti Ngurah Rai	51
Tabel 4.3 Statistika Deskriptif Data Penumpang dan Kargo Bandara Juanda	52
Tabel 4.4 Deteksi <i>Outlier</i> Data Jumlah Penumpang Domestik yang Berangkat	55
Tabel 4.5 Penjelasan Data Terjadinya <i>Outlier</i>	55
Tabel 4.6 Hasil pengujian Signifikansi Parameter Untuk Data Jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	56
Tabel 4.7 Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara Soekarno Hatta	57
Tabel 4.8 Hasil Peramalan Model TSR di Bandara Soekarno Hatta	58
Tabel 4.9 Hasil Uji <i>White Noise</i> Jumlah Penumpang Domestik yang Berangkat dari Bandara Soekarno Hatta	59
Tabel 4.10 Hasil pengujian Signifikansi Parameter untuk Data Jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	60
Tabel 4.11 Ringkasan Hasil Pengujian Asumsi Model ARIMAX di Bandara Soekarno Hatta	61
Tabel 4.12 Hasil Peramalan Model ARIMAX di Bandara Soekarno Hatta	62
Tabel 4.13 Hasil Pengujian Nonlinieritas di Bandara Soekarno Hatta	63
Tabel 4.14 Pemilihan <i>hidden neuron</i> model TSR-NN data jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	64
Tabel 4.15 Hasil Peramalan Model Hibrida TSR-NN di Bandara Soekarno Hatta	66
Tabel 4.16 Pemilihan <i>hidden neuron</i> model ARIMAX-NN data jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	68

Tabel 4.17	Hasil Peramalan Model hibrida ARIMAX-NN di Bandara Soekarno Hatta	69
Tabel 4.18	Hasil pencarian MAPE Terkecil model SVR data residual TSR Jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	70
Tabel 4.19	Hasil Peramalan Model hibrida TSR-SVR di Bandara Soekarno Hatta	71
Tabel 4.20	Hasil pencarian MAPE Terkecil model SVR data residual ARIMAX Jumlah Penumpang Domestik yang Berangkat dari Soekarno Hatta	73
Tabel 4.21	Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara Soekarno Hatta	74
Tabel 4.22	Hasil Akurasi Peramalan Data <i>Out-Sample</i> Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara Soekarno Hatta	75
Tabel 4.23	Angka Ramalan Penumpang Udara dan Kargo Di Bandara Soekarno Hatta Periode Bulan September 2017 hingga Desember 2018	78
Tabel 4.24	Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara I Gusti Ngurah Rai	81
Tabel 4.25	Hasil Peramalan Model TSR di Bandara I Gusti Ngurah Rai	83
Tabel 4.26	Ringkasan Hasil Pengujian Asumsi Model ARIMAX di Bandara I Gusti Ngurah Rai	83
Tabel 4.27	Hasil Peramalan Model ARIMAX di Bandara I Gusti Ngurah Rai	85
Tabel 4.28	Hasil Pengujian Nonlinieritas di Bandara I Gusti Ngurah Rai	85
Tabel 4.29	Hasil Peramalan Model Hibrida TSR-NN di Bandara I Gusti Ngurah Rai	86
Tabel 4.30	Hasil Peramalan Model Hibrida ARIMAX-NN di Bandara I Gusti Ngurah Rai	87
Tabel 4.31	Hasil Peramalan Model Hibrida TSR-SVR di Bandara I Gusti Ngurah Rai	88
Tabel 4.32	Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara I Gusti Ngurah Rai	89
Tabel 4.33	Hasil Akurasi Peramalan Data <i>Out-Sample</i> Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara I Gusti Ngurah Rai	90
Tabel 4.34	Angka Ramalan Penumpang Udara dan Kargo Di Bandara I Gusti Ngurah Rai Periode Bulan September 2017 hingga Desember 2018	93

Tabel 4.35	Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara Juanda	96
Tabel 4.36	Hasil Peramalan Model TSR di Bandara Juanda	98
Tabel 4.37	Ringkasan Hasil Pengujian Asumsi Model ARIMAX di Bandara Juanda	98
Tabel 4.38	Hasil Peramalan Model ARIMAX di Bandara Juanda	100
Tabel 4.39	Hasil Pengujian Nonlinieritas di Bandara Juanda	100
Tabel 4.40	Hasil Peramalan Model Hibrida TSR-NN di Bandara Juanda	101
Tabel 4.41	Hasil Peramalan Model Hibrida ARIMAX-NN di Bandara Juanda	102
Tabel 4.42	Hasil Peramalan Model Hibrida TSR-SVR di Bandara Juanda	103
Tabel 4.43	Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara Juanda	104
Tabel 4.44	Hasil Akurasi Peramalan Data <i>Out-Sample</i> Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara Juanda	105
Tabel 4.45	Angka Ramalan Penumpang Udara dan Kargo Di Bandara Juanda Periode Bulan September 2017 hingga Desember 2018	108

DAFTAR GAMBAR

	Halaman
Gambar 2.1. Prosedur Box-Jenkins	12
Gambar 2.2. Arsitektur FFNN	24
Gambar 2.3. Arsitektur FFNN, p neuron input, q neuron di hidden layer, dan satu neuron output	25
Gambar 2.4. Batas Residual dalam SVR	29
Gambar 2.5. Arsitektur SVR menggunakan pendekatan FFNN	31
Gambar 3.1. Diagram Alir Tahapan Analisis	43
Gambar 3.2. Ilustrasi Pembentukan Model Hibrida TSR-NN dan ARIMAX- NN	44
Gambar 3.3. Ilustrasi Pembentukan Model Hibrida TSR-SVR dan ARIMAX-SVR	44
Gambar 4.1. Plot <i>Time Series</i> Data Penumpang yang Berangkat (a) dan yang Datang (b), serta Kargo yang Dimuat (c) dan yang Dibongkar (d) Kumulatif Tiga Bandara Internasional	45
Gambar 4.2. Pengaruh Minggu Terhadap Rata-rata Penumpang yang Berangkat (a) dan yang Datang (b), serta Kargo yang Dimuat (c) dan yang Dibongkar (d) di Ketiga Bandara Internasional	46
Gambar 4.3. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Soekarno Hatta.....	48
Gambar 4.4. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara I Gusti Ngurah Rai	50
Gambar 4.5. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Juanda	53
Gambar 4.6. Plot ACF sebelum <i>white noise</i> (a) dan plot ACF sesudah <i>white noise</i> (b) pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta	54

Gambar 4.7. Plot ACF dan PACF residual hasil regresi <i>time series</i> pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta	59
Gambar 4.8. Arsitektur Pemodelan NN untuk residual TSR data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta	65
Gambar 4.9. Arsitektur Pemodelan NN untuk residual ARIMAX data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta	68
Gambar 4.10. Hasil ramalan <i>out-sample</i> pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Soekarno Hatta	76
Gambar 4.11. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara Soekarno Hatta	77
Gambar 4.12. Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara Soekarno Hatta	79
Gambar 4.13. Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara Soekarno Hatta	80
Gambar 4.14. Hasil ramalan <i>out-sample</i> pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara I Gusti Ngurah Rai	91
Gambar 4.15. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai.....	92
Gambar 4.16 Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara I Gusti Ngurah Rai ...	94
Gambar 4.17. Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara I Gusti Ngurah Rai	95
Gambar 4.18. Hasil ramalan <i>out-sample</i> pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang	

internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Juanda.....	106
Gambar 4.19. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara Juanda.	107
Gambar 4.20. Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara Juanda	109
Gambar 4.21. Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara Juanda	110
Gambar 4.22. Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (a) dan Datang (b) Kumulatif Tiga Bandara	111
Gambar 4.23. Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) Kumulatif Tiga Bandara	112
Gambar 4.24. Frekuensi Model Terbaik Berdasarkan Kriteria MAPE Pada Data <i>In-Sample</i> Penumpang (a) dan Kargo (b), serta Data <i>Out-Sample</i> Penumpang (c) dan Kargo (d)	113

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. <i>Syntak SAS Time Series Regression</i>	123
Lampiran 2. <i>Syntak SAS ARIMAX Variasi Kalender</i>	124
Lampiran 3. <i>Syntak R Pengujian Nonlinieritas</i>	125
Lampiran 4. <i>Syntak R hybrid TSR-NN</i>	126
Lampiran 5. <i>Syntak R hybrid ARIMAX-NN</i>	128
Lampiran 6. <i>Syntak R hybrid TSR-SVR</i>	130
Lampiran 7. <i>Syntak R hybrid ARIMAX-SVR</i>	133
Lampiran 8. Hasil Uji Asumsi Model TSR dan ARIMAX	136
Lampiran 9. Hasil Estimasi Parameter Model TSR dan ARIMAX	150
Lampiran 10. Arsitektur FFNN Terbaik <i>Hybrid</i> TSR-NN dan ARIMAX- NN	163
Lampiran 11. Pemilihan Parameter Model <i>Hybrid</i> TSR-SVR dan ARIMAX-SVR dengan Menggunakan Metode <i>Grid Search</i> ..	175

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Peranan jasa transportasi udara secara global sangat penting dalam menghubungkan penduduk di seluruh dunia serta meningkatkan perekonomian negara-negara di dunia. Selama beberapa tahun terakhir terjadi peningkatan jumlah permintaan lalu lintas transportasi udara di hampir semua negara yang tercermin dari peningkatan frekuensi penerbangan pesawat, peningkatan jumlah penumpang udara dan peningkatan kargo. Peningkatan jumlah penumpang didukung oleh berbagai aspek, jika dilihat dari sisi penawaran antara lain peningkatan daya tarik wisata, peningkatan konektivitas antar wilayah dan pengembangan rute penerbangan (Fairbanks, 2012). Sedangkan berdasarkan aspek permintaan dapat berupa peningkatan pendapatan yang siap dibelanjakan, peningkatan dalam industri intensif penerbangan dan kecenderungan yang lebih tinggi untuk terbang (bisnis, rekreasi, dan mobilitas masyarakat).

Pasar industri penerbangan di dunia juga tumbuh pesat seiring dengan maraknya penerbangan murah *Low Cost Carrier (LCC)* atau di negara maju dikenal dengan "*Legacy Carriers*" yaitu sebuah bentuk ideal antara pihak konsumen dan operator penerbangan pada tingkat harga yang sesuai dengan daya beli masyarakat. Kebutuhan akan pertumbuhan transportasi udara, tidak hanya untuk penumpang tetapi juga untuk barang. Proses globalisasi dan perkembangan pasar *e-commerce* dunia menyebabkan meningkatnya volume perdagangan yang tercermin dengan peningkatan transportasi yang cepat dan andal di dunia.

Peramalan untuk penumpang udara dan kargo memiliki pengaruh besar terhadap *master plans* pengembangan infrastruktur bandara baik dari *airside* (landasan pacu, *apron*/tempat parkir pesawat, *taxiway*, *air traffic controller*, dan perangkat teknologi), maupun *landside*/terminal (*area boarding/landing*, ruang tunggu, parkir, dan lainnya). Biederman (1993) juga mengatakan bahwa perkiraan jangka panjang untuk penumpang dan kargo merupakan variabel kunci dalam

proyek infrastruktur yang terkait dengan bandara, serta investasi oleh maskapai penerbangan sipil.

Penelitian tentang lalu lintas transportasi udara telah banyak dilakukan di hampir semua negara. Beberapa penelitian yang telah mengembangkan model yang sesuai untuk meramalkan arus lalu lintas udara, antara lain Lai dan Lu (2005) serta Blunk, Clark, dan McGibany (2006) yang mengevaluasi dampak insiden teroris 11 September 2001 terhadap penerbangan domestik Amerika Serikat dengan model permintaan; dan Matsumoto (2004) serta Grosche, Rothlauf, dan Heinzl (2007) yang memprediksi jumlah penumpang dan volume kargo sistem penerbangan dengan model gravitasi. Selain para peneliti, berbagai instansi yang memiliki peraturan perencanaan untuk infrastruktur lalu lintas udara, serta perusahaan swasta seperti produsen pesawat terbang dan maskapai penerbangan, juga telah mengembangkan model sendiri untuk memprediksi perilaku jumlah penumpang, fluktuasi volume barang/kargo dan faktor lainnya.

Peramalan *time series* menggunakan Model *Autoregressive Integrated Moving Average* (ARIMA) paling banyak diadopsi dalam studi empiris. Hasil penelitian Lim dan McAleer (1999) mengungkapkan adanya keberadaan pola musiman pada kedatangan turis internasional dari Malaysia ke Australia dengan menggunakan model ARIMA. Selain itu, Chen, Chang, dan Chang (2009) dan Tsui, Balli, Gilbey, dan Gow (2014) masing-masing meramalkan penumpang udara yang masuk ke Taiwan dan lalu lintas penumpang di Bandara Internasional Hongkong dengan membandingkan beberapa model *univariate time series*.

Pergerakan penumpang udara dan kargo terdapat pola nonlinier yang tersembunyi dan secara implisit muncul ketidakaturan dari musiman dan tren. Model nonlinier seringkali dapat lebih mewakili kondisi data yang ada, karena terkadang ditemui data yang tidak memenuhi asumsi linieritas pada model linier. Pendekatan *machine learning* yang paling banyak diimplementasikan dalam peramalan model nonlinier *time series* adalah *artificial intelligence* meliputi *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM). Zhang, Patuwo, dan Hu (1998) menyebutkan bahwa keunggulan utama dari ANN adalah suatu metode yang adaptif berbasis data dan memiliki kemampuan yang fleksibel dalam memodelkan data nonlinier. Terdapat beberapa penelitian mengenai lalu

lintas udara yang menggunakan pendekatan ANN antara lain Faraway dan Chatfield (1998), Weatherford, Gentry, dan Wilamowski (2003), Medeiros, McAleer, Slotje, Ramos, dan Rey-Maqueira (2008), Blinova (2007) serta Ghomi dan Forghani (2016).

SVM adalah salah satu dari algoritma data mining dan juga dikategorikan sebagai algoritma jaringan syaraf tiruan (ANN) baru untuk peramalan. Cortes dan Vapnik (1995) mengembangkan algoritma *machine learning* yang disebut *Support Vector Network* yang kemudian menjadi *Support Vector Machine* (SVM). SVM telah banyak digunakan dalam berbagai analisis seperti pendekatan regresi, klasifikasi dan pendekatan nonlinier. SVM yang digunakan untuk masalah regresi yang disebut *Support Vector Regression* (SVR). Berkat keunggulan algoritma SVM dalam memecahkan masalah nonlinier, SVM dapat digunakan untuk meramalkan lalu lintas transportasi udara dengan akurasi tinggi. Heng, Zheng, dan Li (2009) meramalkan volume kargo udara dari Beijing ke Shanghai menggunakan metode SVM. Selain itu, Shabri (2015) membandingkan model SARIMA dan model *Least Square Support Vector Machine* (LSSVM) pada data empiris jumlah penumpang udara internasional di Malaysia. Berdasarkan akurasi peramalan terlihat bahwa model LSSVM mampu menangkap musiman dari data *time series* dan menghasilkan peramalan yang lebih akurat.

Khashei dan Bijari (2010) menunjukkan bahwa pada beberapa penelitian model nonlinier secara signifikan lebih baik dibandingkan model linier dengan hasil peramalan yang lebih akurat, namun pada penelitian yang lain model nonlinier menunjukkan hasil yang tidak konsisten. Hal ini juga disebutkan dalam hasil kompetisi M3 (Makridakis dan Hibon, 2000) sebagai berikut: (1) metode statistika yang canggih atau kompleks tidak selalu memberikan perkiraan yang lebih akurat daripada yang sederhana; (2) peringkat kinerja peramalan berbagai metode bervariasi sesuai dengan ukuran akurasi yang digunakan; (3) akurasi ketika beberapa metode individu dikombinasikan, akan menghasilkan akurasi yang lebih baik dibandingkan dengan metode lainnya; serta (4) akurasi berbagai metode bergantung pada panjang horison peramalan. Berdasarkan hasil kompetisi M3 tersebut, kombinasi metode peramalan lebih dari satu model akan meningkatkan akurasi peramalan. Bahkan Gooijer dan Hyndman (2006) dalam

jurnal yang berjudul “25 years of time series” mengatakan bahwa mengkombinasikan peramalan, pencampuran, atau penggabungan kuantitatif peramalan yang diperoleh dari metode *time series* dan sumber informasi yang berbeda telah dipelajari selama tiga dekade terakhir.

Dalam perkembangannya, Zhang (2003) mengkombinasikan dua model individu yang saling melengkapi yang disebut sebagai metode peramalan hibrida. Zhang menggunakan metode peramalan hibrida ARIMA-ANN yang merupakan kombinasi model linier ARIMA dan model nonlinier ANN dengan tujuan untuk menangkap berbagai bentuk hubungan dalam data *time series* dan meningkatkan kinerja peramalan dibandingkan dengan model individunya. Beberapa peneliti yang mengaplikasikan model peramalan hibrida ARIMA-ANN antara lain Zou, Xia, Yang, dan Wang (2007), Shahwan dan Odening (2007), Díaz-Robles, Ortega, Fu, Reed, Chow, Watson, dan Moncada-Herrera (2008), Faruk (2010), Amjady, Daraeepour, dan Keynia (2010), Barba, Rodríguez, dan Montt (2014), serta lainnya. Selain itu, metode hibrida ARIMA-SVM juga telah banyak diterapkan antara lain untuk peramalan harga saham oleh Pai dan Lin (2005); peramalan nilai produksi industri mesin Taiwan oleh Chen dan Wang (2007); dan peramalan lalu lintas penumpang udara China oleh Ming, Bao, Hu, dan Xiong (2014).

Sebagai negara kepulauan, peranan transportasi udara di Indonesia sangat penting dalam menghubungkan dan memajukan semua wilayah di Indonesia, memperkuat perekonomian serta kehidupan sosial dan budaya. Indonesia memiliki 13.466 pulau yang terdaftar di Perserikatan Bangsa-Bangsa dan tersebar di 34 provinsi, 416 kabupaten dan 7.145 kecamatan (BPS, 2017). Kebutuhan akan jasa transportasi udara di Indonesia juga diperkirakan akan terus tumbuh seiring dengan menggeliatnya pertumbuhan ekonomi dan pertumbuhan penduduk.

Menurut data Kementerian Perhubungan (2016), Indonesia memiliki 289 bandara dengan bandara internasionalnya sebanyak 24 bandara. Sepanjang tahun 2016, jumlah pesawat internasional yang berangkat dari bandara internasional Indonesia sebanyak 96.966 pesawat dan jumlah pesawat domestik baik yang berangkat dari bandara internasional maupun bandara domestik sebanyak 876.095 pesawat (BPS, 2017). Tiga bandara internasional dengan kontribusi terbesar di Indonesia antara lain Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai, dan

Bandara Juanda. Ketiga bandara internasional tersebut menyumbang 55,52 persen jumlah penumpang udara yang berangkat dari Indonesia dan 68,50 persen jumlah volume kargo yang di muat di Indonesia.

Berdasarkan yang telah diuraikan sebelumnya, penelitian ini akan melakukan pemodelan dan peramalan jumlah penumpang udara dan volume kargo di tiga bandara internasional Indonesia menggunakan kombinasi metode peramalan hibrida. Penelitian ini juga melakukan perbandingan beberapa metode hibrida peramalan, agar dapat diketahui metode peramalan hibrida yang memiliki kinerja peramalan terbaik.

1.2 Rumusan Masalah

Berdasarkan pada latar belakang di atas, maka rumusan masalah dalam penelitian adalah:

1. Bagaimana pemodelan jumlah penumpang udara dan kargo di tiga bandara internasional Indonesia dengan metode peramalan hibrida?
2. Kombinasi peramalan metode hibrida mana yang paling akurat dalam meramalkan jumlah penumpang udara dan kargo di tiga bandara internasional Indonesia?
3. Bagaimana peramalan setahun kedepan jumlah penumpang udara dan kargo di tiga bandara internasional Indonesia?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Memperoleh beberapa model peramalan hibrida jumlah penumpang udara dan kargo di tiga bandara internasional Indonesia.
2. Memperoleh metode peramalan terbaik untuk jumlah penumpang udara dan kargo di tiga bandara internasional Indonesia.
3. Memperoleh nilai peramalan setahun kedepan penumpang udara dan kargo di tiga bandara internasional Indonesia.

1.4 Manfaat Penelitian

Manfaat yang ingin dicapai dari hasil penelitian ini antara lain:

1. Menghasilkan suatu model yang mampu menjelaskan jumlah penumpang udara dan kargo di Indonesia.
2. Menjadi salah satu alternatif bagi Pemerintah atau Badan Pusat Statistik (BPS) dalam memprediksi jumlah penumpang udara dan kargo di Indonesia.
3. Hasil ramalan yang diperoleh dapat sebagai bahan masukan terhadap kebijakan pemerintah dalam menangani masalah transportasi udara berkaitan dengan perencanaan infrastruktur bandara dan pengembangannya.
4. Mengembangkan wawasan keilmuan dan ilmu pengetahuan tentang metode peramalan hibrida bagi peneliti.

1.5 Batasan Penelitian

Dalam penelitian ini ruang lingkup permasalahan dibatasi pada:

1. Pada penelitian ini wilayah yang diteliti hanya tiga bandara internasional dengan kontribusi penumpang dan kargo terbesar di Indonesia yaitu Bandara Internasional Soekarno Hatta, Bandara Internasional I Gusti Ngurah Rai, dan Bandara Internasional Juanda. Data yang dianalisis pada wilayah tersebut menggunakan seri bulanan periode Januari 2001 hingga Agustus 2017.
2. Metode yang akan digunakan untuk menyusun model terbaik peramalan lalu lintas penumpang dan volume barang transportasi udara pada penelitian ini adalah metode peramalan hibrida *time series*. Metode linier *time series* yang akan digunakan adalah regresi *time series* (TSR) dan ARIMAX, sedangkan metode nonliniernya menggunakan NN dan SVR. Sehingga kinerja peramalan metode hibrida yang akan dibandingkan antara lain metode hibrida TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR.

BAB 2

TINJAUAN PUSTAKA

Pada bab ini diuraikan tinjauan dari berbagai literatur yang terkait dengan penelitian. Pokok bahasan dalam bab ini meliputi sejarah penerbangan di Indonesia dan perkembangan transportasi udara di Indonesia. Selain itu juga akan diuraikan pembahasan konsep dasar *time series*, model peramalan klasik *time series* (regresi *time series*, ARIMA, dan ARIMAX), model peramalan berbasis *machine learning* (NN dan SVR), serta model peramalan hibrida.

2.1 Sejarah Penerbangan di Indonesia

Berdasarkan data Kementerian Perhubungan (2016), penerbangan pertama di Indonesia terjadi sejak tanggal 19 Februari 1913. Seorang penerbang asal Belanda bernama J.W.E.R Hilger menerbangkan sebuah pesawat jenis Fokker dalam kegiatan pameran yang berlangsung di Surabaya. Penerbangan tersebut tercatat sebagai penerbangan pertama di Hindia Belanda (Indonesia). Melihat prospek yang baik bagi penerbangan sipil maupun militer di Indonesia, maka pada tanggal 1 Oktober 1924 sebuah pesawat jenis Fokker F-7 maskapai penerbangan Belanda melakukan penerbangan dari Bandara Schiphol Amsterdam ke Jakarta.

Bandar Udara Internasional Kemayoran merupakan bandar udara pertama di Indonesia untuk penerbangan internasional. Landasan bandar udara ini dibangun pada tahun 1934 dan secara resmi dibuka tanggal 8 Juli 1940. Namun sebenarnya sejak tanggal 6 Juli 1940, bandar udara ini beroperasi dimulai pesawat pertama yang mendarat jenis DC-3 Dakota milik perusahaan penerbangan Hindia Belanda, KNILM (*Koninklijke Nederlands Indische Luchtvaart Maatschappij*). Pada tanggal 28 Desember 1949, terjadi penerbangan bersejarah pesawat DC-3 dengan registrasi PK-DPD milik KLM yang membawa Presiden Soekarno dari Yogyakarta ke Kemayoran untuk pelantikan sebagai Presiden Republik Indonesia Serikat (RIS). Presiden Soekarno memberikan logo dan nama baru *Garuda Indonesian Airways* kepada perusahaan penerbangan pertama tersebut.

Pada tahun 1952 pemerintah membentuk “Djawatan Penerbangan Sipil” yang bertanggung jawab kepada Kementerian Perhubungan Udara, tugasnya adalah

menangani administrasi, pengusahaan dan pembangunan perhubungan udara. Djawatan Penerbangan Sipil merupakan cikal bakal Direktorat Jenderal Perhubungan Udara. PT Angkasa Pura I merupakan pelopor pengelola bandar udara secara komersial di Indonesia. Tanggal 15 November 1962 terbit Peraturan Pemerintah (PP) Nomor 33 Tahun 1962 tentang Pendirian Perusahaan Negara (PN) Angkasa Pura Kemayoran. Tugas pokoknya adalah untuk mengelola dan mengusahakan Bandar Udara Internasional Kemayoran di Jakarta yang merupakan satu-satunya bandar udara yang melayani penerbangan dari dan ke luar negeri selain penerbangan domestik. Bandar udara Kemayoran resmi berhenti beroperasi pada tanggal 31 Maret 1985 dengan dimulainya pemindahan aktivitas penerbangan ke Bandar Udara Internasional Soekarno Hatta.

2.2 Perkembangan Transportasi Udara di Indonesia

Sejalan dengan perkembangan ekonomi global, transportasi udara di Indonesia semakin mudah diakses oleh semua lapisan masyarakat. Hal ini mendorong perkembangan infrastruktur bandara di seluruh wilayah Indonesia menjadi berkembang pesat sesuai dengan meningkatnya permintaan. Menurut data Kementerian Perhubungan (2016), Indonesia memiliki 289 bandara dengan bandara internasional sebanyak 24 bandara. Jumlah pesawat internasional yang berangkat dari bandara internasional Indonesia pada tahun 2016 sebanyak 96.966 pesawat dan jumlah pesawat domestik baik yang berangkat dari bandara internasional maupun bandara domestik sebanyak 876.095 pesawat (BPS, 2017).

Kepemilikan dan pengelolaan bandara di Indonesia terbagi di antara beberapa operator. PT Angkasa Pura 1 bertanggung jawab atas pengoperasian tiga belas bandara termasuk dua gudang kargo dan satu pusat kontrol lalu lintas udara di wilayah timur Indonesia. Sedangkan PT Angkasa Pura 2 bertanggung jawab atas pengoperasian tiga belas bandara lainnya di wilayah barat Indonesia. Sebanyak 263 bandara yang dimiliki atau dioperasikan secara terpisah, baik secara langsung oleh pemerintah provinsi, perusahaan swasta, atau melalui unit pelaksana teknis di bawah Kementerian Perhubungan.

Enam bandara internasional dengan kontribusi terbesar di Indonesia antara lain Bandara Soekarno Hatta, Bandara Juanda, Bandara I Gusti Ngurah Rai,

Bandara Kualanamu, Bandara Hassanudin, dan Bandara Sepinggan yang menyumbang sebesar 71 persen dari total penumpang yang berangkat dari Indonesia dan 83 persen dari total kargo yang dimuat di Indonesia sepanjang tahun 2016 (Kementerian Perhubungan, 2016). Tabel 2.1 menunjukkan kapasitas dan realisasi tahun 2016 pada enam bandara internasional tersebut.

Tabel 2.1 Kapasitas Penumpang dan Kargo serta Realisasinya Tahun 2016

Bandara	Kapasitas Penumpang (orang/Tahun)	Kapasitas Kargo (Kg/Tahun)	Jumlah Penumpang (2016)	Jumlah Kargo (Kg/2016)
Soekarno Hatta	58.700.000	342.473.000	58.195.484	597.807.352
I Gusti Ngurah Rai	24.025.218	50.753.681	20.001.275	51.560.079
Juanda	10.500.000	59.156.625	19.486.330	96.280.587
Sultan Hasanuddin	7.564.620	59.156.624	10.756.737	57.897.859
Kualanamu	8.500.000	65.000.000	8.959.483	43.691.877
SAMS Sepinggan	7.727.617	43.201.416	7.518.437	53.644.322

Sumber : PT Angkasa Pura I dan PT Angkasa Pura II (2016)

Peningkatan lalu lintas udara di masa mendatang diperkirakan tidak sejalan jika dibandingkan dengan kapasitas yang tersedia di bandara-bandara tersebut. Akibatnya, beberapa bandara beroperasi di atas kapasitas normalnya dan tidak mampu mengatasi peningkatan permintaan penumpang dan pertumbuhan kargo. Selain bandara, peningkatan fasilitas pengendalian lalu lintas udara, termasuk komunikasi, navigasi dan pengawasan, serta manajemen lalu lintas udara, yang didukung oleh proses dan prosedur yang tepat, akan diperlukan untuk menjamin tidak terjadi penyempitan (*bottleneck*) wilayah udara (Fairbanks, 2012).

2.3 Analisis *Time Series*

Time series merupakan serangkaian observasi terhadap suatu variabel yang diambil secara berurutan berdasarkan interval waktu yang tetap. Analisis *time series* memiliki kombinasi dari beberapa macam komponen, seperti *trend*, siklus (*cycle*), *seasonal* atau musiman, dan residual (Hyndman, Koehler, Ord, dan Snyder, 2008). *Trend* adalah data series yang menunjukkan arah secara kontinu naik atau turun. *Seasonal* adalah sebuah pola pengulangan dengan periode yang diketahui. Contoh: 12 bulan pertahun, 7 hari perminggu. *Cycle* merupakan pola pengulangan

yang teratur namun dengan periode berubah-ubah (contoh: siklus bisnis). Sedangkan residual merupakan komponen *series* yang tidak dapat diprediksi.

2.4 Model *Time Series Regression* (TSR)

Regresi *time series* memiliki bentuk yang sama dengan regresi linier pada umumnya. Dengan mengasumsikan output y_t , untuk $t = 1, 2, \dots, n$, yang dipengaruhi oleh kemungkinan data input, dimana inputnya diketahui, hubungan ini dapat ditunjukkan dengan model regresi linier (Shumway dan Stoffer, 2006). Secara umum, model regresi *time series* jika terdapat tren, seasonal, dan *dummy* efek variasi kalender dituliskan seperti persamaan (2.1).

$$y_t = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + N_t, \quad (2.1)$$

dengan δ adalah parameter tren linier, β adalah parameter musiman, dan $S_{m,t}$ adalah variabel *dummy* musiman. Apabila datanya bulanan, maka M akan sebanyak 12 variabel *dummy* seasonal. Sedangkan jika datanya triwulanan, maka M akan sebanyak 4 variabel *dummy* dan seterusnya. γ , φ , dan ϑ merupakan parameter kejadian bulan saat terjadinya efek variasi kalender, satu bulan sebelum terjadinya efek variasi kalender dan satu bulan setelah terjadinya efek variasi kalender. Apabila efek variasi kalender dibuat dalam bentuk mingguan, maka G akan sebanyak 4 variabel *dummy* variasi kalender. Sedangkan jika efek variasi kalender dibuat dalam bentuk harian, maka G akan sebanyak 30 variabel *dummy*. $V_{g,t}$ adalah variabel *dummy* kejadian bulan saat terjadinya efek variasi kalender, $V_{g,t-1}$ adalah variabel *dummy* kejadian satu bulan sebelum terjadinya efek variasi kalender, dan $V_{g,t+1}$ adalah variabel *dummy* kejadian satu bulan sesudah terjadinya efek variasi kalender. Sedangkan N_t adalah residual yang belum *white noise*.

Jumlah efek variasi kalender dapat diidentifikasi berdasarkan *plot time series*. Apabila error belum *white noise*, *lag* digunakan sebagai tambahan variabel prediktor. Pemilihan *lag* dapat ditentukan berdasarkan plot ACF dan PACF (Lee, Suhartono, dan Hamzah, 2010). Misalkan pada model regresi *time series*, *lag* yang signifikan adalah lag $1, 2, \dots, p$ maka persamaan model regresi *time series* akan menjadi persamaan (2.2).

$$y_t = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + \sum_{t=1}^p \alpha_p y_{t-p} + a_t \quad (2.2)$$

dengan α adalah parameter *autoregressive* dan a_t adalah residual yang sudah *white noise*.

2.5 Model ARIMA

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model peramalan linier yang dihasilkan dari kombinasi model *Autoregressive* (AR) dan *Moving Average* (MA). Model ini seringkali digunakan dalam peramalan data *time series* dan untuk peramalan jangka pendek (Wei, 2006). Bentuk umum model ARIMA orde (p, d, q) dengan *differencing* sebanyak d yaitu:

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t. \quad (2.3)$$

Untuk data yang mengandung pola musiman, model ARIMA yang digunakan dapat dinotasikan sebagai ARIMA $(P, D, Q)^S$. Untuk pola datanya dapat dirumuskan (Wei, 2006):

$$\Phi_P(B^S)(1-B^S)^D Y_t = \theta_0 + \Theta_Q(B^S)a_t. \quad (2.4)$$

Model gabungan musiman dan non musiman ARIMA $(p, d, q) (P, D, Q)^S$ merupakan model multiplikatif musiman Box-Jenkins (Wei, 2006), secara umum dituliskan seperti:

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D Y_t = \theta_0 + \theta_q(B)\Theta_Q(B^S)a_t, \quad (2.5)$$

dengan θ_0 adalah rata-rata dari data stasioner (dengan atau tanpa *differencing*),

$\phi_p(B)$ adalah koefisien komponen AR tanpa periode musiman orde p ,

$\Phi_P(B^S)$ adalah koefisien komponen AR periode musiman S orde P ,

$\theta_q(B)$ adalah koefisien komponen MA tanpa periode musiman orde q ,

$\Theta_Q(B^S)$ adalah koefisien komponen MA periode musiman S orde Q ,


a_t adalah residual *white noise* dengan mean 0 dan varians σ_a^2 atau

$$a_t \sim WN(0, \sigma_a^2),$$

$(1-B)^d$ adalah *differencing* tanpa musiman dengan orde d ,

$(1 - B^S)^D$ adalah *differencing* musiman S dengan orde D .

Peramalan ARIMA dengan prosedur Box-Jenkins dimulai dari tahap identifikasi model, estimasi parameter, cek diagnosa dan peramalan dapat digambarkan pada Gambar 2.1 (Makridakis dan Hibon, 1997).



Gambar 2.1. Prosedur Box-Jenkins

2.5.1 Identifikasi Model

Menurut Wei (2006), identifikasi model ARIMA dilakukan melalui tiga tahapan, yaitu :

Tahap 1. Cek *Plot data time series*, apabila data belum stasioner maka tentukan transformasi yang sesuai.

Data yang dianalisis dengan model ARIMA harus memenuhi syarat memiliki sifat stasioner baik pada *mean* maupun *varians*. Stasioner dalam mean berarti memiliki rata-rata yang tetap (tidak dipengaruhi jalannya waktu) dan variansnya tetap (homoskedastisitas). Apabila ternyata data belum stasioner dalam mean, maka harus dilakukan proses *differencing*. Sedangkan apabila belum stasioner dalam varians, maka dapat diatasi dengan transformasi Box-Cox.

Proses *differencing* merupakan proses pembedaan atau pengurangan suatu data dengan data sebelumnya sampai data tersebut menjadi stasioner. Apabila suatu

data *time series* tidak stasioner, maka data tersebut dapat dijadikan lebih mendekati stasioner dengan melakukan proses pembedaan pertama (*first difference*) seperti:

$$Y'_t = Y_t - Y_{t-1} \quad (2.6)$$

atau

$$Y'_t = (1 - B)Y_t. \quad (2.7)$$

Pembedaan pertama dinyatakan oleh $(1 - B)$.

Jika setelah proses *first difference* data masih belum stasioner, maka dilakukan proses *differencing* kedua (*second difference*) diberi notasi $(1 - B)^2$. Maka secara umum apabila terdapat pembedaan orde d untuk mencapai stasioneritas, dapat dituliskan seperti:

$$\Delta^d Y_t = (1 - B)^d Y_t. \quad (2.8)$$

Kestasioneran varians dapat dideteksi dari nilai varians data yang bersifat konstan atau tetap. Untuk mengatasi data dengan varians tidak homogen dapat dilakukan dengan transformasi. Metode transformasi yang sering digunakan adalah model transformasi yang diperkenalkan oleh Box dan Cox pada tahun 1964, ditunjukkan:

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}, \quad (2.9)$$

dengan λ adalah parameter transformasi (Wei, 2006).

Bentuk transformasi Box-Cox untuk beberapa nilai estimasi yang sering digunakan ditunjukkan pada Tabel 2.2.

Tabel 2.2 Nilai Transformasi Box Cox

Nilai λ	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0,0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	Y_t tidak ditransformasi

Sumber: Wei (2006)

Uji stasioneritas varians tersebut ditampilkan dalam bentuk plot Box-Cox. Jika nilai batas bawah dan batas atas lambda dari data *time series* mengandung nilai satu, maka varians data tersebut sudah stasioner.

Tahap 2. Hitung dan periksa nilai ACF dan PACF. ACF digunakan untuk menjelaskan korelasi antara Y_t dan Y_{t+k} dari suatu proses yang sama dan hanya terpisah oleh *lag* waktu ke- k (Wei, 2006). Korelasi antara Y_t dan Y_{t+k} ditunjukkan:

$$\rho_k = \frac{Cov(Y_t, Y_{t+k})}{\sqrt{var(Y_t)}\sqrt{var(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.10)$$

dimana ρ_k adalah nilai autokorelasi pada *lag* waktu ke- k , dengan $k = 1, 2, \dots$
 $Cov(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) = \gamma_k$, dan $var(Y_t) = var(Y_{t+k}) = \gamma_0$.
 Fungsi autokorelasi (ACF) untuk sampel secara umum dapat dituliskan seperti:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}. \quad (2.11)$$

Sedangkan PACF digunakan untuk mengukur tingkat keeratan hubungan pada data *time series* antara Y_t dan Y_{t+k} setelah pengaruh $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan (Wei, 2006). Fungsi parsial autokorelasi (PACF) ditunjukkan:

$$P_k = \frac{Cov[(Y_t - \hat{Y}_t), (Y_{t+k} - \hat{Y}_{t+k})]}{\sqrt{var(Y_t - \hat{Y}_t)}\sqrt{var(Y_{t+k} - \hat{Y}_{t+k})}} \quad (2.12)$$

dengan $\hat{Y}_t = \beta_1 Y_{t+1} + \beta_2 Y_{t+2} + \dots + \beta_{k-1} Y_{t+k-1}$

$$\hat{Y}_{t+k} = \alpha_1 Y_{t+k-1} + \alpha_2 Y_{t+k-2} + \dots + \alpha_{k-1} Y_{t+1}.$$

Fungsi PACF untuk sampel dinotasikan dengan $\hat{\phi}_{kk}$ dan dihitung dengan menggunakan persamaan Durbin (1960) dalam (Wei, 2006) seperti:

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad (2.13)$$

dengan $\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}$, dan $j = 1, 2, \dots, k$.

Tahap 3. Hitung dan periksa ACF dan PACF dari data yang telah stasioner, berdasarkan pola teoritik untuk menentukan order ARIMA p dan q . Sebagai panduan pola teoritik tersebut dapat dilihat pada Tabel 2.3.

Tabel 2.3 Pola Teoritik ACF dan PACF dari order ARMA

Proses	ACF	PACF
AR(p)	Menurun secara eksponensial (<i>dies down</i>)	Terpotong setelah lag p (<i>cut off</i>)
MA(q)	Terpotong setelah lag q (<i>cut off</i>)	Menurun secara eksponensial (<i>dies down</i>)
ARMA(p,q)	Menurun secara eksponensial (<i>dies down</i>) setelah lag $(q - p)$	Menurun secara eksponensial (<i>dies down</i>) setelah lag $(p - q)$

Sumber: Wei (2006)

2.5.2 Estimasi dan Uji Signifikansi Parameter

Setelah melakukan identifikasi dan diperoleh model selanjutnya adalah melakukan uji kelayakan model ARIMA sementara yang diperoleh. Model dianggap layak jika mempunyai parameter yang signifikan. Dalam Wei (2006), ada beberapa cara estimasi parameter untuk model ARIMA, yaitu estimasi dengan metode momen, estimasi dengan metode *least square*, dan estimasi dengan metode *maximum likelihood*.

Penelitian ini menggunakan metode *least square*, karena metode ini bekerja dengan membuat *error* yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat *error* (SSE). Ilustrasi penerapan metode *least square* untuk estimasi parameter model AR(1) ditunjukkan:

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + a_t \quad (2.14)$$

Model pada persamaan (2.14) dapat dilihat sebagai suatu model regresi dengan variabel prediktor Y_{t-1} dan variabel respon Y_t . Estimasi *least squares* dilakukan dengan cara mencari nilai parameter yang meminimumkan jumlah kuadrat error, seperti dituliskan:

$$S(\phi_1, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)]^2. \quad (2.15)$$

Biasanya persamaan ini disebut *conditional sum-of squares function*. Melalui penerapan diferensial terhadap μ dan kemudian disamakan dengan 0, akan diperoleh estimasi parameter model AR(1).

$$\hat{\mu} = \frac{\sum_{t=2}^n Y_t - \phi_1 \sum_{t=2}^n Y_{t-1}}{(n-1)(1-\phi_1)}, \quad (2.16)$$

dan untuk n yang besar,

$$\frac{\sum_{t=2}^n Y_t}{(n-1)} \approx \frac{\sum_{t=2}^n Y_{t-1}}{(n-1)} \approx \bar{Y},$$

sehingga persamaan (2.16) dapat direduksi menjadi:

$$\hat{\mu} = \frac{\bar{Y} - \phi_1 \bar{Y}}{(1-\phi_1)} = \bar{Y}. \quad (2.17)$$

Dengan cara yang sama, persamaan (2.15) didifferensial terhadap ϕ_1 dan diperoleh:

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_t - \bar{Y})^2}. \quad (2.18)$$

Dari hasil persamaan (2.18) dapat dijelaskan bahwa metode *least squares* akan menghasilkan nilai estimasi parameter yang hampir identik dengan metode momen, terutama untuk data yang besar (n besar).

Tahap selanjutnya adalah melakukan uji kelayakan model ARIMA. Jika uji terhadap parameter adalah signifikan, maka model dianggap layak. Hipotesis yang digunakan dalam uji signifikansi parameter model AR adalah sebagai berikut:

$$H_0: \phi = 0$$

$$H_1: \phi \neq 0$$

dengan $\hat{\phi}$ adalah estimasi parameter model AR. Statistik uji yang digunakan adalah menggunakan uji t dituliskan seperti:

$$t_{hit} = \frac{\hat{\phi}}{\widehat{se}(\hat{\phi})}. \quad (2.19)$$

Daerah penolakan H_0 adalah $|t_{hit}| > t_{\frac{\alpha}{2}, n-n_p}$, dengan n_p adalah banyaknya parameter dalam model, n adalah banyaknya observasi, dan $\widehat{se}(\hat{\phi})$ adalah nilai taksiran *standar error* dari model AR.

Hipotesis yang digunakan untuk melakukan pengujian signifikansi parameter model MA adalah sebagai berikut:

$$H_0: \theta = 0$$

$$H_1: \theta \neq 0$$

dengan $\hat{\theta}$ adalah estimasi parameter model MA. Statistik uji yang digunakan adalah menggunakan uji t dituliskan seperti:

$$t_{hit} = \frac{\hat{\theta}}{\widehat{se}(\hat{\theta})}. \quad (2.20)$$

Daerah penolakan H_0 adalah $|t_{hit}| > t_{\frac{\alpha}{2}, n-n_q}$, dengan n_q adalah banyaknya parameter dalam model MA, n adalah banyaknya observasi, dan $\widehat{se}(\hat{\theta})$ adalah nilai taksiran *standar error* dari model MA. Adapun varians untuk beberapa model ARIMA dapat ditunjukkan oleh Tabel 2.4 (Cryer dan Chan, 2008).

Tabel 2.4 Varians Parameter ARIMA

Model ARIMA	Varians
AR(1)	$\text{var}(\hat{\phi}) \approx \frac{1-\phi^2}{n}$
AR(2)	$\text{var}(\hat{\phi}_1) \approx \text{var}(\hat{\phi}_2) \approx \frac{1-\phi_2^2}{n}$
MA(1)	$\text{var}(\hat{\theta}) \approx \frac{1-\theta^2}{n}$
MA(2)	$\text{var}(\hat{\theta}_1) \approx \text{var}(\hat{\theta}_2) \approx \frac{1-\theta_2^2}{n}$
ARMA(1,1)	$\text{var}(\hat{\phi}) \approx \left[\frac{1-\phi^2}{n} \right] \left[\frac{1-\phi\theta}{\phi-\theta} \right]^2$ $\text{var}(\hat{\theta}) \approx \left[\frac{1-\theta^2}{n} \right] \left[\frac{1-\phi\theta}{\phi-\theta} \right]^2$

2.5.3 Cek Diagnosa Model

Langkah selanjutnya setelah memperoleh estimasi yang terbaik dalam model adalah melakukan cek diagnosa model, yakni memeriksa apakah model yang diestimasi telah sesuai apabila asumsi *white noise* telah terpenuhi. Asumsi *white noise* adalah suatu kondisi residual dengan rata-rata nol dan varians konstan (σ_a^2) yang identik, independen dan berdistribusi normal. Pengujian asumsi residual yang saling tidak berkorelasi dapat menggunakan Q-statistik (Uji Ljung-Box) dan asumsi residual normal dapat menggunakan uji Kolmogorov-Smirnov.

- Residual (a_t) bersifat independen

Uji asumsi residual yang bersifat independen atau *white noise*, atau dapat dikatakan tidak terdapat korelasi antar residual dengan nilai rata-rata nol dan varians konstan (σ_a^2). Hipotesis yang digunakan dalam uji Ljung-Box (Wei, 2006):

$$H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0 \text{ (tidak ada korelasi antar residual)}$$

$$H_1: \text{minimal ada satu } \rho_k \neq 0, \text{ dengan } k = 1, 2, 3, \dots, K,$$

dengan statistik uji sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)} \quad (2.21)$$

dimana Q mengikuti distribusi $\chi_{(K-m)}^2$ dengan $m = p + q$. Daerah penolakan H_0 adalah $Q > \chi_{\alpha; K-m}^2$.

b. Residual (a_t) berdistribusi normal

Uji kenormalan terhadap residual dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hipotesis pada uji kenormalan adalah sebagai berikut:

$$H_0: F(a_t) = F_0(a_t), \text{ untuk semua } a_t$$

$$H_1: F(a_t) \neq F_0(a_t), \text{ untuk semua } a_t,$$

dengan statistik uji yaitu:

$$D = \text{Sup}|S(a_t) - F_0(a_t)|, \quad (2.22)$$

$S(a_t)$ = fungsi distribusi data residual yang belum diketahui

$F(a_t)$ = fungsi distribusi kumulatif dari data asal residual.

Daerah penolakan H_0 jika $D \geq D_{\alpha, n}$ atau jika $p_{value} < \alpha$. Nilai kritis $D_{\alpha, n}$ dapat diperoleh dari tabel Kolmogorov-Smirnov dengan jumlah sampel dan α yang bersesuaian.

2.5.4 Peramalan ARIMA

Tahapan terakhir yang dilakukan dalam analisis *time series* adalah tahap peramalan (Wei, 2006). Suatu model ARIMA dengan $d = 0$ atau ARMA (p, q) yang stasioner secara umum didefinisikan dalam bentuk:

$$\phi(B)Y_t = \theta(B)a_t, \quad (2.23)$$

atau dapat ditulis dalam representasi MA sebagai berikut:

$$Y_t = \psi(B)a_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots, \quad (2.24)$$

dimana,

$$\psi(B) = \sum_{j=0}^{\infty} \psi_j B^j = \frac{\theta(B)}{\phi(B)}, \quad (2.25)$$

dan $\psi_0 = 1$. Untuk $t = n + l$, akan menjadi:

$$Y_{n+l} = \sum_{j=0}^{\infty} \psi_j a_{n+l-j}, \quad (2.26)$$

dengan menggunakan ramalan minimum *Mean Square Error* akan diperoleh:

$$\hat{Y}_n(l) = \psi_l a_n + \psi_{l+1} a_{n-1} + \psi_{l+2} a_{n-2} + \dots. \quad (2.27)$$

$\hat{Y}_n(l)$ biasa dibaca sebagai ramalan pada langkah ke- l dari Y_n , sehingga untuk kesalahan ramalan pada l langkah ke depan diperoleh:

$$e_n(l) = Y_n(l) - \hat{Y}_n(l) = \sum_{j=0}^{l-1} \psi_j a_{n+l-j}. \quad (2.28)$$

sehingga variansi kesalahan ramalan pada l langkah ke depan ditulis seperti:

$$Var(e_n(l)) = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2. \quad (2.29)$$

2.6 Model Autoregressive Integrated Moving Average with Exogenous Factor (ARIMAX)

Model ARIMAX merupakan pengembangan dari model ARIMA. Pada ARIMAX, faktor eksogen yang dianggap signifikan dimasukkan ke dalam model. Model ARIMAX yang digunakan di dalam penelitian ini adalah model variasi kalender. Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Komposisi hari dalam seminggu bervariasi dari bulan ke bulan dan tahun ke tahun. Beberapa kejadian seperti Ramadhan, Idul Fitri, Paskah, Tahun Baru Cina, dan Nyepi yang diatur dengan kalender dan tanggal tersebut dapat bervariasi dari tahun ke tahun. Model ARIMA musiman dapat dituliskan seperti:

$$Y_t = \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t, \quad (2.30)$$

dimana a_t merupakan residual yang sudah *white noise* dengan rata-rata 0 dan varians konstan. Sehingga model ARIMAX dengan komponen tren, musiman dan variasi kalender dijelaskan:

$$Y_t = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t. \quad (2.31)$$

Adapun penjelasan masing-masing parameter regresi *time series* telah dibahas pada sub bab 2.4. Sedangkan untuk model:

$\frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t$ merupakan model ARIMA $(p, d, q) (P, D, Q)^S$.

Prosedur pembentukan ARIMAX dengan adanya komponen tren, musiman, serta efek variasi kalender dapat dirinci sebagai berikut (Lee, Suhartono, dan Hamzah, 2010):

- 1) Menentukan variabel *dummy* dengan komponen tren, musiman dan efek variasi kalender.
- 2) Meregresikan variabel *dummy* tersebut dengan data asli untuk mendapatkan residual.
- 3) Memodelkan residual tersebut menggunakan model ARIMA (gunakan prosedur Box-Jenkins).
- 4) Order dari model ARIMA yang diperoleh dari langkah ke-3 digunakan untuk data asli dan variabel *dummy* sebagai variabel input secara bersamaan pada persamaan (2.31).
- 5) Uji signifikansi dari parameter dan melakukan cek diagnosa asumsi residual *white noise* dan berdistribusi normal.

2.7 Deteksi *Outlier*

Outlier dalam suatu data deret waktu merupakan suatu data pengamatan yang tidak konsisten sebagai akibat dari adanya kejadian luar biasa yang tidak

terduga dan tanpa disadari seperti pemogokan, wabah perang, krisis politik atau ekonomi yang berkejolak. Pengamatan tersebut biasa dikenal dalam *time series* berupa *outlier*. Deteksi *outlier* pertama kali diperkenalkan oleh Fox (1972) dalam (Wei 2006). *Outlier* terdiri dari beberapa tipe, yaitu *additive outlier* (AO), *innovational outlier* (IO), *level shift* (LS) dan *temporary change* (TC).

2.7.1 Additive Outlier (AO)

Additive Outlier (AO) merupakan kejadian yang mempengaruhi suatu deret runtun waktu pada satu waktu saja. X_t diasumsikan mengikuti pola ARMA (p, q) Wei (2006) mendefinisikan model *additive outlier* seperti:

$$Y_t = \begin{cases} X_t, & t \neq T \\ X_t + \omega, & t = T \end{cases} \quad (2.32)$$

atau

$$\begin{aligned} Y_t &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta_q(B)}{\phi_p(B)} a_t + \omega I_t^{(T)} \end{aligned} \quad (2.33)$$

dengan

$$I_t^{(T)} = \begin{cases} 1, & t \neq T \\ 0, & t = T \end{cases}$$

X_t adalah model ARMA sebelum deteksi *outlier*

T adalah waktu kejadian terjadinya *outlier*

$I_t^{(T)}$ adalah variabel *outlier* pada waktu ke- T .

2.7.2 Innovational Outlier (IO)

Data *time series* yang mengandung *innovational outlier* (IO) memberikan efek yang lebih rumit jika dibandingkan ketiga tipe *outlier* lainnya. Wei (2006) mendefinisikan model IO pada:

$$\begin{aligned} Y_t &= X_t + \frac{\theta_q(B)}{\phi_p(B)} \omega I_t^{(T)} \\ &= \frac{\theta_q(B)}{\phi_p(B)} (a_t + \omega I_t^{(T)}). \end{aligned} \quad (2.34)$$

Efek AO hanya terjadi pada T observasi saja, sedangkan pada IO mempengaruhi seluruh observasi Y_t dengan $t \geq T$ atau $t = T, T + 1, \dots$ dari sistem yang diberikan oleh $\frac{\theta_q(B)}{\phi_p(B)}$.

2.7.3 Level Shift (LS)

Level Shift merupakan kejadian yang mempengaruhi deret pada satu waktu tertentu dan memberikan efek suatu perubahan yang tiba-tiba dan permanen. Model *Level Shift* pada data runtun waktu dapat dinyatakan persamaan (2.35) (Wei 2006).

$$Y_t = X_t + \frac{1}{(1 - B)} \omega_L I_t^{(T)}. \quad (2.35)$$

2.7.4 Temporary Change (TC)

Temporary Change adalah suatu kejadian dimana outlier menghasilkan efek awal pada waktu ke- t sebesar ω_t dan kemudian efek tersebut berkurang secara perlahan sesuai dengan besarnya δ . Model TC dinyatakan persamaan (2.36).

$$Y_t = X_t + \frac{1}{(1 - \delta B)} \omega_L I_t^{(T)}, \quad (2.36)$$

dengan $|\delta| < 1$. Pada saat $\delta = 0$ maka TC akan menjadi kasus AO sedangkan pada saat $\delta = 1$ maka TC akan menjadi LS.

2.8 Uji Nonlinieritas pada Data Time Series

Sebelum menerapkan model nonlinier terlebih dahulu dilakukan uji nonlinieritas pada data *time series*, hal ini dilakukan untuk memastikan bahwa metode yang digunakan sudah sesuai dengan datanya. Ada beberapa uji nonlinieritas yang sudah dikembangkan, salah satunya uji Terasvirta. Uji Terasvirta adalah uji deteksi nonlinearity yang dikembangkan dari model *Neural Network* dan termasuk dalam kelompok uji tipe *Lagrange Multiplier* (LM) yang dikembangkan dengan ekspansi Taylor (Terasvirta, Lin, dan Granger, 1993).

Implementasi praktis dari uji linieritas, yang dikenalkan oleh Terasvirta, Lin, dan Granger (1993), dapat dilakukan melalui dua statistik uji, yaitu uji χ^2 atau uji F . prosedur uji χ^2 untuk uji linieritas ini sebagai berikut:

1. Meregresikan y_t pada X_t , maka diperoleh model linier:

$$y_t = \beta_0 + \beta_1 X_t + u_t \quad (2.37)$$

Kemudian diperoleh nilai residual $u_t = y_t - \hat{y}_t$.

2. Menambahkan variabel independen misalkan \hat{X}_t^2 , sehingga diperoleh model nonlinier:

$$y_t = \beta_0 + \beta_1 X_t + \theta_1 \hat{X}_t^2 + v_t \quad (2.38)$$

dengan v_t merupakan komponen nilai residual.

3. Untuk ukuran sampel besar, perhitungan statistik uji secara asimtotis mengikuti χ^2 . Maka perhitungan statistik uji dapat dilakukan $\chi^2 = nR^2$, dengan n adalah banyaknya pengamatan yang digunakan dan R^2 merupakan koefisien determinasi dari model regresi persamaan (2.38).
4. Dibawah hipotesis linieritas $H_0: \theta_1 = 0$, χ^2 mendekati distribusi $\chi^2(m)$, dengan m adalah banyaknya prediktor, untuk persamaan (2.38) maka $m = 2$. Daerah penolakan H_0 , apabila χ^2 hitung lebih besar $\chi^2(m)$, atau nilai p -value kurang dari taraf uji $\alpha = 0,05$. Sehingga dapat dikatakan suatu model linier belum cukup untuk memodelkan hubungan antara prediktor dengan respon karena ada komponen nonlinier yang belum masuk dalam model (terabaikan) atau dikatakan sebagai *neglected nonlinearity*. Pada kondisi tersebut maka perlu dibangun model nonlinier untuk estimasi model yang lebih sesuai.

2.9 Model Neural Network (NN)

Artificial Neural Network (ANN) atau dikenal dengan *Neural Network* (NN) merupakan suatu jaringan syaraf tiruan yang dikembangkan untuk meniru cara kerja otak manusia (Zhang, Patuwo, dan Hu, 1998). NN digunakan sebagai suatu instrumen untuk menyelesaikan berbagai permasalahan aplikasi seperti *pattern recognition*, *signal processing* dan *process control*. Struktur *neuron* pada NN berhubungan secara erat dengan algoritma pembelajaran yang digunakan. Secara mendasar, terdapat dua arsitektur NN (Haykin, 2009):

a. Feed Forward Neural Networks (FFNN)

Arsitektur FFNN ini bersifat *feed forward* atau asiklik (*acyclic*). FFNN terdiri dari *single layer* FFNN dan *multi layer* FFNN. Dalam *single layer* FFNN *input layer* langsung menuju ke *output layer*, namun tidak berlaku sebaliknya.

Sedangkan pada *multi layer* FFNN, arsitektur FFNN terdapat tambahan satu atau lebih *hidden layer*.


b. *Recurrent Networks*

Berbeda dengan arsitektur FFNN, arsitektur *Recurrent networks* memiliki satu atau lebih koneksi balik (*feedback loop*). Sebagai contoh, suatu *recurrent networks* terdiri dari suatu lapisan dimana setiap *neuron* mengirimkan kembali sinyal output yang dihasilkan sebagai input pada *neuron* lainnya.

2.9.1 *Feed Forward Neural Networks*


FFNN atau disebut juga sebagai *Multilayer Perceptrons* (MLP), merupakan arsitektur NN yang paling banyak digunakan dalam aplikasi di bidang teknik atau rekayasa. Biasanya, aplikasi NN untuk pemodelan *time series* dan *signal processing* adalah berdasarkan pada arsitektur MLP. MLP merupakan arsitektur NN yang tersusun dari satu *input layer*, satu atau lebih *hidden layer*, dan satu *output layer* (Haykin, 2009). *Input layer* berfungsi sebagai tempat data dimasukkan untuk proses lebih lanjut, *hidden layer* merupakan unit proses dari data yang telah dimasukkan, *output layer* merupakan tempat keluaran hasil dari proses yang telah dilakukan. sedangkan *weights* adalah penimbang yang selalu berubah setiap diberikan input.

Gambar 2.2. menunjukkan arsitektur FFNN dengan satu *hidden layer* (Moghadam dan Keshmirpour, 2011). Setiap *layer* memiliki *neuron* atau *node* yang mentransfer hasilnya ke *layer* berikutnya dengan menggunakan fungsi transfer. Aliran sinyal melalui *network* berlanjut ke arah depan, dari kiri ke kanan dan berdasarkan *layer* demi *layer*.



Gambar 2.2. Arsitektur FFNN

Pada *input layer* tidak terdapat pemrosesan informasi, informasi yang tersedia pada *input layer* diteruskan pada *neuron* yang terdapat pada *hidden layer*. Fungsi aktivasi masing-masing *neuron* pada *hidden layer* melakukan pemrosesan dengan menjumlahkan penimbang dari *neuron* pada *input layer* yang ditambahkan dengan suatu nilai (*bias*). Output dari *neuron* pada *hidden layer* kemudian diteruskan ke *neuron* pada *output layer* (Gambar 2.3). Spesifikasi arsitektur model NN dalam hal jumlah input dan *hidden neuron* bukanlah tugas yang mudah. Percobaan dengan arsitektur yang berbeda sering dilakukan untuk mengidentifikasi model yang tepat.



Gambar 2.3. Arsitektur FFNN, p neuron input layer, q neuron di hidden layer, dan satu neuron output layer

Arsitektur tersebut menjelaskan nilai variabel respon atau output (\hat{y}_t) dan input ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) memiliki representasi matematis seperti:

$$\hat{y}_t = f^o \left[\sum_{j=1}^q \left\{ w_j^o f_j^h \left(\sum_{i=1}^p w_{ij}^h y_{t-i} + b_j^h \right) + b^0 \right\} \right], \quad (2.39)$$

dengan \hat{y}_t merupakan nilai dugaan dari variabel output, y_{t-i} merupakan variabel input ($i = 1, 2, \dots, p$), w_{ij}^h merupakan penimbang dari *neuron* input layer ke- i ke *neuron* ke- j dari *hidden layer*, b_j^h merupakan bias pada *neuron* ke- j di *hidden layer* ($j = 1, 2, \dots, q$), w_j^o merupakan penimbang dari *neuron* ke- j dari *hidden layer* ke *neuron* pada *output layer*, dan b^0 merupakan bias pada *neuron* di *output layer*. p adalah jumlah dari *input layer* dan q adalah jumlah dari *hidden layer*. f_j^h adalah

fungsi aktivasi di *neuron* ke- j pada *hidden layer* dan f^0 adalah fungsi aktivasi di *neuron* pada *output layer*. Superscript o dan h pada fungsi aktivasi dan penimbang menunjukkan indeks *output layer* dan indeks *hidden layer*.

Fungsi aktivasi nonlinier yang terdapat pada setiap *neuron* dalam lapisan arsitektur FFNN ditekankan untuk dapat memenuhi syarat *smooth nonlinearity* (dapat diturunkan atau *differentiable*). Fungsi aktivasi nonlinier yang banyak digunakan untuk *hidden layer* dan memenuhi syarat tersebut adalah fungsi *sigmoid*, yang didefinisikan melalui suatu fungsi logistik (Bishop, 1995). Persamaan matematis fungsi aktivasi sigmoid, adalah:

$$f(x) = \frac{1}{1 + \exp(-x)}, \quad (2.40)$$

sedangkan fungsi aktivasi linier $f(x) = x$, digunakan pada *output layer*.

2.9.2 Algoritma *Back-Propagation*

FFNN telah menunjukkan keberhasilannya dalam pengaplikasian terhadap penyelesaian masalah yang kompleks dengan memberikan pembelajaran *supervised* melalui algoritma yang sangat populer, yaitu *back-propagation algorithm* (Haykin, 2009). Algoritma *back-propagation* berdasarkan data training $\{(x(n); d(n))\}_{n=1}^N$ dapat diuraikan sebagai berikut (Haykin, 2009):

1. Inisialisasi. Dengan mengasumsikan bahwa tidak ada informasi sebelumnya yang tersedia dan pilih secara acak dengan nilai yang sangat kecil.
2. Jadikan *data training* sebagai input. Pada *network*, tentukan siklus pelatihan (*epoch*) dari *data training*. Untuk setiap *set data training*, lakukan proses komputasi *forward* dan *backward* pada langkah 3 dan 4.
3. Komputasi *forward*. Misalkan *data training* dinotasikan sebagai $(x(n), d(n))$, dengan input berupa vektor $x(n)$ pada *input layer* dan vektor respon $d(n)$ yang berada pada *output layer*. Hitung penjumlahan tertimbang dan fungsi sinyal dari network secara maju *layer* demi *layer* yang dilalui. Penjumlahan tertimbang $w_j^{(l)}(n)$ untuk *neuron* j pada *layer* l adalah:

$$w_j^{(l)}(n) = \sum_{i=1}^{m_0} w_{ij}^{(l)} y_i^{(l-1)}(n), \quad (2.41)$$

dimana $y_i^{(l-1)}(n)$ adalah output dari fungsi sinyal *neuron* i pada layer sebelumnya $l - 1$ pada iterasi ke- n , dan $w_{ij}^{(l)}$ adalah penimbang dari *neuron* i pada layer l yang berasal dari *neuron* j pada layer $l - 1$. Untuk $i = 0$, diperoleh $y_0^{(l-1)}(n) = +1$ dan $w_j^{(l)}(n) = b_j^{(l)}(n)$ yang merupakan bias *neuron* j pada layer l . Dengan asumsi menggunakan fungsi *sigmoid*, sinyal output *neuron* j pada layer l adalah:

$$y_j^{(l)} = \varphi_j(w_j(n)). \quad (2.42)$$

Jika *neuron* j berada pada *hidden layer* pertama ($l = 1$), tentukan:

$$y_i^{(0)}(n) = x_j(n), \quad (2.43)$$

dimana $x_j(n)$ adalah elemen ke- j dari vektor input $x(n)$.

Jika *neuron* j berada pada *output layer* ($l = L$), dimana L merupakan kedalaman dari *network*, tentukan:

$$y_j^{(L)} = o_j(n). \quad (2.44)$$

Hitung nilai residual:

$$e_j(n) = d_j(n) - o_j(n), \quad (2.45)$$

dimana $d_j(n)$ merupakan elemen ke j dari vektor respon $d(n)$.

4. Komputasi *backward*. Hitung nilai δ (gradien lokal), yang didefinisikan sebagai:

$$\delta_j^{(L)}(n) = \begin{cases} e_j^{(L)}(n)\varphi_j'(w_j^{(L)}(n)) & , \text{ untuk } \textit{neuron } j \text{ pada } \textit{output } L \\ \varphi_j'(w_j^{(L)}(n)) \sum_i \delta_i^{(l+1)}(n)w_{ij}^{(l+1)}(n) & , \text{ untuk } \textit{neuron } j \text{ pada } \textit{output } l \end{cases}$$

Perbarui penimbang pada *layer* l berdasarkan:

$$w_{ij}^{(l)}(n+1) = w_{ij}^{(l)}(n) + \alpha [w_{ij}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n), \quad (2.46)$$

dimana η merupakan parameter *learning-rate* dan α adalah konstanta.

5. Iterasi. Lakukan iterasi terhadap komputasi *forward* dan *backward* pada langkah 3 dan 4 dengan memberikan *epoch* yang baru pada data *training* sampai kriteria penghentian yang dipilih terpenuhi.

2.10 Model Support Vector Regression (SVR)

SVM adalah suatu jenis *machine learning* yang baru dan secara cepat mendapatkan popularitas karena banyak fitur menarik dan kinerja empiris yang menjanjikan (Cortes dan Vapnik, 1995). SVM berada dalam satu kelas NN, pada NN menemukan solusi beberapa lokal optimal dan SVM menemukan solusi yang global optimal yaitu menghasilkan solusi yang sama pada setiap runningnya. SVM pada awalnya dikembangkan untuk mengatasi masalah klasifikasi namun dalam perkembangannya SVM juga mampu mengatasi masalah regresi yang disebut *Support Vector Regression* (SVR). Berdasarkan prinsip *structural risk minimization* (SRM), SVR berusaha menemukan *hyperlane* terbaik yang memisahkan data serta memperkecil jarak antara *hyperlane* dan data (Pai dan Lin, 2005). Sehingga SVR mendapatkan suatu fungsi dengan tingkat kesalahan paling kecil untuk menghasilkan suatu prediksi yang bagus.

Ide dasar SVR untuk regresi adalah mengenalkan fungsi kernel, memetakan data input ke dalam ruang fitur berdimensi tinggi dengan pemetaan nonlinier dan kemudian melakukan regresi linier di ruang fitur (Shabri dan Suhartono, 2012). Data penelitian dibagi menjadi data *training* dan data *testing*. Kemudian dari data *training* tersebut ditentukan suatu fungsi regresi dengan batasan deviasi tertentu sehingga dapat menghasilkan prediksi yang mendekati dari target aktual.

Fungsi regresi dari metode SVR dirumuskan sebagai berikut:

$$f(x) = \mathbf{w}^T \phi(x) + b, \quad (2.47)$$


dimana \mathbf{w} adalah vektor pembobot, $\phi(x)$ adalah fungsi yang memetakan secara non linier x dari ruang input kedalam suatu ruang fitur berdimensi tinggi, dan b adalah bias. Koefisien \mathbf{w} dan b diestimasi dengan cara meminimalkan fungsi resiko yang didefinisikan dalam persamaan sebagai berikut:

$$R(f(x)) = C \sum_{i=1}^T L_{\varepsilon}(\mathbf{y}_i, f(\mathbf{x}_i)) + \frac{1}{2} \|\mathbf{w}\|^2, \quad (2.48)$$

dimana

$$L_{\varepsilon}(\mathbf{y}_i, f(\mathbf{x}_i)) = \begin{cases} |\mathbf{y}_i - f(\mathbf{x}_i)| \leq \varepsilon, & 0 \\ |\mathbf{y}_i - f(\mathbf{x}_i)| - \varepsilon, & \text{lainnya} \end{cases}$$

dengan L_ε merupakan ε -insensitive loss function, $\frac{1}{2}\|\mathbf{w}\|$ merupakan vektor pembobot norm, \mathbf{y}_i adalah vektor dari nilai sebenarnya, C dan ε merupakan parameter yang sudah ditentukan. C adalah konstanta yang mengevaluasi *trade-off* antara kompleksitas model dan sejauh mana penyimpangan yang lebih besar dari ε ditoleransi. ξ_i^*, ξ_i merupakan positif *slack* variabel, yang mewakili jarak dari nilai sebenarnya ke nilai batas yang sesuai dari ε .



Gambar 2.4. Batas Residual dalam SVR

Gambar 2.4 (a) menunjukkan bagaimana nilai residual pada SVR dihitung. Sampai dengan garis batas residual pada ε , nilai residual dianggap sama dengan 0, sedangkan di luar batas tersebut nilai residual akan dihitung sebagai ξ_i dan ξ_i^* (Haykin, 2009). Solusi pada masalah ini adalah sebuah garis yang memiliki toleransi terhadap residual seperti yang ditunjukkan pada Gambar 2.4 (b).

Fungsi f diasumsikan dapat mengaproksimasi semua titik (x_i, y_i) dengan presisi ε . Apabila semua titik berada dalam rentang $f \pm \varepsilon$ disebut *feasible*. Sedangkan *infeasible* merupakan kondisi dimana ada beberapa titik yang mungkin keluar dari rentang $f \pm \varepsilon$. Titik-titik yang *infeasible* bisa ditambahkan variabel slack ξ_i^*, ξ_i untuk mengatasi masalah *infeasible constraint*. Sehingga optimasi pada persamaan (2.48) dapat ditransformasi ke dalam bentuk berikut:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*), \quad (2.49)$$

dengan batasan: $\mathbf{y}_i - \mathbf{w}^T \phi(\mathbf{x}_i) - b \leq \varepsilon + \xi_i$,

$$\mathbf{w}^T \phi(\mathbf{x}_i) - b \leq \varepsilon + \xi_i,$$

$$\mathbf{w}^T \phi(\mathbf{x}_i) + b - \mathbf{y}_i \leq \varepsilon + \xi_i^*, \text{ dan}$$

$$\xi_i^*, \xi_i \geq 0, i = 1, 2, \dots, n.$$

Optimalisasi pada batasan tersebut bisa diselesaikan menggunakan *primal lagrangian* dalam bentuk sebagai berikut:

$$L(\mathbf{w}, b, \xi, \xi^*, \alpha_i, \alpha_i^*, \beta_i, \beta_i^*) \quad (2.50)$$

$$\begin{aligned} &= \frac{1}{2} \|\mathbf{w}\|^2 + c \left(\sum_{i=1}^n (\xi_i + \xi_i^*) \right) \\ &\quad - \sum_{i=1}^n \alpha_i [\mathbf{w}^T \phi(\mathbf{x}_i) + b - \mathbf{y}_i + \varepsilon + \xi_i^*] \\ &\quad - \sum_{i=1}^n \alpha_i^* [\mathbf{y}_i - \mathbf{w}^T \phi(\mathbf{x}_i) - b + \varepsilon + \xi_i^*] - \sum_{i=1}^n (\beta_i \xi_i + \beta_i^* \xi_i^*) \end{aligned}$$

Persamaan (2.50) diminimalkan pada variabel primal $\mathbf{w}, b, \xi, \xi^*$ dan dimaksimalkan dalam bentuk *lagrangian multiplier* nonnegatif $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*$ lalu didapatkan *dual lagrangian* pada persamaan (2.52) dengan fungsi kernel. Fungsi kernel bertujuan untuk memetakan data dari ruang input ke ruang fitur (ruang berdimensi tinggi). Sehingga untuk kasus nonlinier, fungsi kernel mampu mendeteksi hubungan linier dalam ruang fitur tersebut. Fungsi kernel $K(\mathbf{x}_i, \mathbf{x})$ dapat dinyatakan sebagai inner product $\phi(\mathbf{x}_i)^T \phi(\mathbf{x})$. Salah satu fungsi kernel yang paling sering digunakan adalah *Gaussian radial basis function* (RBF) (Härdle, Prastyo, dan Hafner, 2014):

$$K(\mathbf{x}_i, \mathbf{x}) = \exp \left(-\frac{\|\mathbf{x}_i - \mathbf{x}\|^2}{2\sigma^2} \right), \quad (2.51)$$


dimana σ^2 adalah parameter kernel yang diperoleh hingga mendapatkan hasil yang global optimum.

$$\begin{aligned} \partial(\alpha_i, \alpha_i^*) &= \sum_{i=1}^n \mathbf{y}_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) \\ &\quad - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(\mathbf{x}_i, \mathbf{x}). \end{aligned} \quad (2.52)$$

Sehingga didapatkan fungsi regresi sebagai berikut:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b. \quad (2.53)$$

Sedangkan dalam peramalan data *time series* input x yang digunakan adalah *lag* dari data pengamatan $x = [y_{t-1}, y_{t-2}, \dots, y_{t-p}]$. Arsitektur SVR diimplementasikan dengan pendekatan model FFNN, kompleksitas model dikendalikan dengan menjaga jumlah ruang fitur kecil (*hidden neuron*) ditunjukkan pada Gambar 2.5 (Haykin, 2009). Di sisi lain, SVR menawarkan solusi untuk merancang *machine learning* dengan mengendalikan kompleksitas model secara independen dari dimensi (Smola dan Schölkopf, 2004).



Gambar 2.5. Arsitektur SVR menggunakan pendekatan FFNN

Salah satu algoritma untuk menentukan parameter optimal pada model SVR adalah menggunakan algoritma *grid search*. Algoritma ini membagi jangkauan parameter yang akan dioptimalkan kedalam *grid* dan melintasi semua titik untuk mendapatkan parameter yang optimal. Dalam aplikasinya, algoritma *grid search* harus dipandu oleh beberapa metrik kinerja, biasanya diukur dengan *cross validation* pada data training (Hsu *et al.*, 2003). Oleh karena itu disarankan untuk mencoba beberapa variasi pasangan parameter pada *hyperplane* SVR.

2.11 Model Peramalan Hibrida

Perilaku permintaan lalu lintas pesawat udara tidak mudah untuk diprediksi. Oleh karena itu, strategi hibrida yang memiliki kemampuan pemodelan linier dan

nonlinier merupakan alternatif yang baik untuk meramalkan jumlah penumpang udara dan pergerakan volume kargo. Pendekatan model linier (TSR dan ARIMAX) mungkin tidak tepat untuk mengatasi permasalahan nonlinier yang kompleks. Di sisi lain, menggunakan model nonlinier (NN dan SVR) untuk permasalahan model linier menghasilkan hasil yang tidak konsisten. Dengan demikian, model hibrida dapat memodelkan pola linier dan nonlinier dengan keseluruhan kinerja peramalan yang meningkat (Chen, 2011).

Zhang (2003) merepresentasikan model peramalan hibrida yang terdiri dari model linier dan nonlinier sebagai berikut:

$$Y_t = L_t + N_t + e_t, \quad (2.54)$$

dimana L_t adalah komponen linier dan N_t adalah komponen nonlinier dari model hibrida. Pertama, data dimodelkan dengan model linier (TSR atau ARIMAX), dan kemudian diperoleh residual N_t pada waktu ke- t dari model linier, sebagai berikut:

$$N_t = Y_t - \hat{L}_t, \quad (2.55)$$

dimana \hat{L}_t menunjukkan nilai ramalan model linier pada waktu ke- t . Kemudian N_t dimodelkan menggunakan model nonlinier (NN atau SVR), sehingga hubungan nonlinier dapat tercakup. Dengan p input, model nonlinier dari residual menjadi sebagai berikut:

$$N_t = f(N_{t-1}, N_{t-2}, \dots, N_{t-p}) + \varepsilon_t \quad (2.56)$$

dengan f adalah fungsi nonlinier yang ditentukan oleh model nonlinier dan ε_t adalah kesalahan acak. Jika model f yang terbentuk tidak sesuai maka ε_t tidak akan sepenuhnya acak, sehingga identifikasi model adalah faktor yang sangat penting. Oleh karena itu, ramalan gabungannya adalah:

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (2.57)$$

dimana \hat{N}_t adalah nilai peramalan pada persamaan (2.56). Penelitian ini membandingkan empat model peramalan hibrida antara lain hibrida TSR-NN, hibrida TSR-SVR, hibrida ARIMAX-NN dan hibrida ARIMAX-SVR.

2.12 Kriteria Pemilihan Model Terbaik

Evaluasi model dilakukan untuk mengetahui seberapa baik model yang terbentuk berdasarkan residual yang dihasilkan. Kriteria pemilihan model terbaik yang digunakan adalah berdasarkan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Nilai RMSE dan MAPE yang digunakan pada data testing untuk evaluasi kebaikan model disimbolkan dengan RMSEP (RMSE *Prediction*) dan MAPEP (MAPE *Prediction*). Pemilihan model terbaik menggunakan nilai RMSEP dan MAPEP. Model terbaik didapatkan jika nilai RMSEP dan MAPEP paling kecil diantara model yang ada, hal ini sesuai dengan tujuan dari peramalan, yaitu untuk memperoleh angka ramalan dengan kesalahan sekecil-kecilnya. Besarnya nilai RMSEP dan MAPEP dapat dihitung dengan formula sebagai berikut (Wei, 2006):

$$\text{RMSEP} = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2} \quad (2.58)$$

$$\text{MAPEP} = \left(\frac{1}{L} \sum_{l=1}^L \left| \frac{Y_{n+l} - \hat{Y}_n(l)}{Y_{n+l}} \right| \right) 100\% \quad (2.59)$$

dengan n adalah banyaknya data *training* (*in sample*), L adalah banyaknya ramalan data *testing* (*out sample*) yang dilakukan, Y_{n+l} adalah data aktual dan $\hat{Y}_n(l)$ adalah data hasil ramalan.

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN

3.1 Sumber Data

Sumber data yang digunakan merupakan data sekunder dari Badan Pusat Statistik (BPS). Data yang digunakan adalah data bulanan jumlah penumpang udara dan volume kargo di tiga bandara internasional Indonesia antara lain Bandara Internasional Soekarno Hatta, Bandara Internasional I Gusti Ngurah Rai, dan Bandara Internasional Juanda. Data jumlah penumpang udara penerbangan internasional maupun penerbangan domestik terdiri dari jumlah penumpang yang berangkat dan datang. Data volume kargo penerbangan internasional maupun penerbangan domestik terbagi menjadi kargo yang dibongkar dan dimuat. Data jumlah penumpang udara dan volume kargo di Indonesia merupakan statistik sektoral yang diterbitkan secara periodik oleh BPS, dimana data tersebut diperoleh dari PT Angkasa Pura 1 dan PT Angkasa Pura 2. Periode data yang digunakan adalah pada rentang waktu bulan Januari 2001 sampai dengan bulan Agustus 2017.

3.2 Variabel Penelitian

Variabel respon dalam penelitian ini jumlah penumpang udara yang disimbolkan $Y_{i,j,t}$, dan volume kargo yang disimbolkan $Z_{i,j,t}$ dengan masing-masing jenis variabel ke $i = 1,2,3,4$, lokasi bandara ke $j = 1,2,3$ yaitu Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai, dan Bandara Juanda, serta waktu ke- t . Secara rinci variabel respon dalam penelitian ini dijabarkan pada Tabel 3.1.

Variabel prediktor yang digunakan dalam pemodelan terdiri dari:

- a. Variabel *dummy* tren kenaikan penumpang dan kargo (t) dengan $t = 1,2,\dots,n$
- b. Variabel *dummy* pola musiman (bulan)

$$\begin{aligned} S_{1,t} &= \begin{cases} 1, & \text{bulan Januari} \\ 0, & \text{bulan lainnya} \end{cases} \\ &\vdots \\ S_{12,t} &= \begin{cases} 1, & \text{bulan Desember} \\ 0, & \text{bulan lainnya} \end{cases} \end{aligned}$$

Tabel 3.1. Variabel Respon dalam Penelitian

No.	Variabel	Bandara Soekarno Hatta	Bandara I Gusti Ngurah Rai	Bandara Juanda
Penumpang				
1	Domestik yang berangkat	$Y_{1,1,t}$	$Y_{1,2,t}$	$Y_{1,3,t}$
2	Domestik yang datang	$Y_{2,1,t}$	$Y_{2,2,t}$	$Y_{2,3,t}$
3	Internasional yang berangkat	$Y_{3,1,t}$	$Y_{3,2,t}$	$Y_{3,3,t}$
4	Internasional yang datang	$Y_{4,1,t}$	$Y_{4,2,t}$	$Y_{4,3,t}$
Kargo				
1	Domestik yang dimuat	$Z_{1,1,t}$	$Z_{1,2,t}$	$Z_{1,3,t}$
2	Domestik yang dibongkar	$Z_{2,1,t}$	$Z_{2,2,t}$	$Z_{2,3,t}$
3	Internasional yang dimuat	$Z_{3,1,t}$	$Z_{3,2,t}$	$Z_{3,3,t}$
4	Internasional yang dibongkar	$Z_{4,1,t}$	$Z_{4,2,t}$	$Z_{4,3,t}$

c. Variabel *dummy* efek variasi kalender

Diduga efek variasi kalender berupa hari raya Idul Fitri berkaitan dengan data jumlah penumpang dan volume kargo di Indonesia. Efek hari raya Idul Fitri berkaitan dengan minggu terjadinya hari raya Idul Fitri satu bulan sebelumnya ($t - 1$), bulan terjadinya hari raya Idul Fitri (t), dan satu bulan setelah hari raya Idul Fitri ($t + 1$). Efek satu bulan sebelum hari raya Idul Fitri, yaitu:

$$V_{1,t-1} = \begin{cases} 1, & \text{satu bulan sebelum Idul Fitri yang terjadi pada minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$\vdots$$

$$V_{4,t-1} = \begin{cases} 1, & \text{satu bulan sebelum Idul Fitri yang terjadi minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

Efek pada bulan hari raya Idul Fitri, yaitu:

$$V_{1,t} = \begin{cases} 1, & \text{bulan saat Idul Fitri yang terjadi pada minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

$$\vdots$$

$$V_{4,t} = \begin{cases} 1, & \text{bulan saat Idul Fitri yang terjadi pada minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

Efek satu bulan setelah hari raya Idul Fitri, yaitu:

$$V_{1,t+1} = \begin{cases} 1, & \text{satu bulan setelah Idul Fitri yang terjadi pada minggu ke-1} \\ 0, & \text{bulan lainnya} \end{cases}$$

⋮

$$V_{4,t+1} = \begin{cases} 1, & \text{satu bulan setelah Idul Fitri yang terjadi pada minggu ke-4} \\ 0, & \text{bulan lainnya} \end{cases}$$

Tanggal terjadinya hari raya Idul Fitri disajikan pada Tabel 3.2 dengan penentuan minggu sebagai berikut:

Minggu ke-1 : tanggal 1 sampai tanggal 7,

Minggu ke-2 : tanggal 8 sampai tanggal 15,

Minggu ke-3 : tanggal 16 sampai tanggal 23,

Minggu ke-4 : tanggal 24 sampai dengan tanggal terakhir pada bulan tersebut.

Tabel 3.2. Tanggal Hari Raya Idul Fitri Periode 2001-2017

Tahun	Tanggal, Bulan (Minggu)	Tahun	Tanggal, Bulan (Minggu)
2001	17-18 Desember (III)	2010	10-11 September (II)
2002	06-07 Desember (I)	2011	30-31 Agustus (IV)
2003	25-26 November (IV)	2012	19-20 Agustus (III)
2004	14-15 November (II)	2013	8-9 Agustus (I)
2005	03-04 November (I)	2014	28-29 Juli (IV)
2006	23-24 Oktober (IV)	2015	17-18 Juli (III)
2007	12-13 Oktober (II)	2016	5-6 Juli (I)
2008	01-02 Oktober (I)	2017	26-27 Juni (IV)
2009	20-21 September (III)		

Sumber : Diolah dari kalender (2001-2017)

3.3 Struktur Data

Adapun struktur data untuk Bandara Soekarno Hatta dijabarkan pada Tabel 3.3. Sedangkan untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai dan Bandara Juanda memiliki struktur data yang sama dengan data Bandara Soekarno Hatta.

Tabel 3.3. Struktur Data Bandara Soekarno Hatta

Bulan – Tahun	Data	Dummy												
		t	Bulan				Variasi Kalender							
			S _{1,t}	...	S _{12,t}	V _{1,t-1}	...	V _{4,t-1}	V _{1,t}	...	V _{4,t}	V _{1,t+1}	...	V _{4,t+1}
Data Penumpang														
Jan-01	Y _{1,1,1}	1	1	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Mei-17	Y _{1,1,197}	197	0	...	0	0	...	1	0	...	0	0	...	0
Juni-17	Y _{1,1,198}	198	0	...	0	0	...	0	0	...	1	0	...	0
Juli-17	Y _{1,1,199}	199	0	...	0	0	...	0	0	...	0	0	...	1
Agust-17	Y _{1,1,200}	200	0	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Jan-01	Y _{4,1,1}	1	1	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Mei-17	Y _{4,1,197}	197	0	...	0	0	...	1	0	...	0	0	...	0
Juni-17	Y _{4,1,198}	198	0	...	0	0	...	0	0	...	1	0	...	0
Juli-17	Y _{4,1,199}	199	0	...	0	0	...	0	0	...	0	0	...	1
Sep-17	Y _{4,1,200}	200	0	...	0	0	...	0	0	...	0	0	...	0
Data Kargo														
Jan-01	Z _{1,1,1}	1	1	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Mei-17	Z _{1,1,197}	197	0	...	0	0	...	1	0	...	0	0	...	0
Juni-17	Z _{1,1,198}	198	0	...	0	0	...	0	0	...	1	0	...	0
Juli-17	Z _{1,1,199}	199	0	...	0	0	...	0	0	...	0	0	...	1
Agust-17	Z _{1,1,200}	200	0	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Jan-01	Z _{4,1,1}	1	1	...	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Mei-17	Z _{4,1,197}	197	0	...	0	0	...	1	0	...	0	0	...	0
Juni-17	Z _{4,1,198}	198	0	...	0	0	...	0	0	...	1	0	...	0
Juli-17	Z _{4,1,199}	199	0	...	0	0	...	0	0	...	0	0	...	1
Sep-17	Z _{4,1,200}	200	0	...	0	0	...	0	0	...	0	0	...	0

3.4 Tahapan Penelitian

Berdasarkan tujuan penelitian maka tahapan dalam penelitian ini meliputi pemodelan dengan metode hibrida TSR-NN, TSR-SVR, ARIMAX-NN, dan ARIMAX-SVR untuk memprediksi jumlah penumpang udara dan kargo di Indonesia.

3.4.1. Tahap Awal

Pada tahap awal, ditentukan jumlah data *training* sebagai *in-sample* dan data *testing* sebagai *out-sample*.

3.4.2. Pemodelan dengan Metode Hibrida TSR-NN

Pemodelan hibrida TSR-NN dilakukan untuk memprediksi jumlah penumpang udara dan kargo di Indonesia dengan tahapan sebagai berikut:

- (1) Pemodelan regresi *time series* dengan variabel *dummy* tren, musiman dan variasi kalender.
- (2) Estimasi parameter dan pengujian signifikansi parameter.
- (3) Cek diagnosa terhadap residual model diantaranya adalah uji *white noise* dan uji distribusi normal. Apabila belum memenuhi asumsi *white noise* maka *lag* yang signifikan ditambahkan sebagai variabel independen.
- (4) Estimasi ulang model.
- (5) Peramalan berdasarkan model regresi *time series*:

$$\hat{Y}_t^{(1)} = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + \sum_{t=1}^p \alpha_p y_{t-p} + N_t.$$

- (6) Hitung residual dari model linier regresi *time series*
- (7) Uji non linieritas model linier TSR.
- (8) Residual TSR digunakan sebagai input dalam pemodelan NN.
- (9) Jumlah *neuron* pada *input layer* ditentukan sebanyak *lag* yang signifikan.
- (10) Penentuan jumlah *neuron* pada *hidden layer* untuk pemodelan diawali dengan 1 (satu) *hidden neuron*. Kemudian *neuron* pada *hidden layer*

diperbarui hingga 10 *neuron* kemudian di analisis nilai MAPEP sebagai dasar pemilihan model NN terbaik.

- (11) Tentukan fungsi aktivasi.
- (12) Pembelajaran jaringan untuk mendapatkan model FFNN.
- (13) Peramalan dengan model NN:

$$\hat{N}_t^{(2)} = f^0 \left[\sum_{j=1}^q \left\{ w_j^0 f_j^h \left(\sum_{i=1}^p w_{ij}^h N_{t-i} + b_j^h \right) + b^0 \right\} \right].$$

- (14) Peramalan model hibrida TSR-NN:

$$\hat{Y}_t = \hat{Y}_t^{(1)} + \hat{N}_t^{(2)}.$$

- (15) Hitung nilai RMSEP dan MAPEP .

3.4.3. Pemodelan dengan Metode Hibrida TSR-SVR

Pemodelan hibrida TSR-SVR dilakukan untuk memprediksi jumlah penumpang udara dan kargo di Indonesia dengan tahapan sebagai berikut:

- (1) Peramalan model regresi *time series* berdasarkan langkah-langkah pada bagian 3.4.2 tahap (1) s/d (6). Sehingga diperoleh model TSR:

$$\begin{aligned} \hat{Y}_t^{(1)} = & \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} \\ & + \sum_{t=1}^p \alpha_p y_{t-p} + N_t. \end{aligned}$$

- (2) Residual TSR digunakan sebagai input dalam pemodelan TSR.
- (3) Penentuan fungsi kernel.
- (4) Penentuan nilai-nilai parameter kernel, C dan *epsilon* untuk optimasi *hyperplane* pada data *training*.
- (5) Pemilihan nilai parameter terbaik menggunakan metode *grid search* pada tiap *hyperlane* dengan cara sebagai berikut:
 - a) Pada data *training*, gunakan tiap bagian sebagai data *testing* dan bagian lainnya sebagai data *training*.
 - b) Optimasi parameter C dan *epsilon* untuk setiap *hyperlane*.
 - c) Menggunakan *hyperlane-hyperlane* tersebut untuk tiap model regresi.
 - d) Hitung residual tiap model regresi.

- e) Hitung nilai MAPEP hasil regresi untuk setiap *hyperplane*.
- f) Menentukan *hyperlane* terbaik.
- (6) Peramalan SVR dengan nilai parameter terbaik:

$$\hat{N}_t^{(2)} = \sum_{i=i}^n (\hat{\alpha}_i - \hat{\alpha}_i^*) \exp\left(-\frac{\|N_i - N_{i^*}\|^2}{2\sigma^2}\right) + b$$

dengan $N_i = [N_{t-1} \ N_{t-2} \ \dots \ N_{t-p}]$ dan $N_{i^*} = [N_{t-2} \ N_{t-3} \ \dots \ N_{t-(p+1)}]$.

- (7) Peramalan model hibrida TSR-SVR:

$$\hat{Y}_t = \hat{Y}_t^{(1)} + \hat{N}_t^{(2)}.$$

- (8) Hitung nilai RMSEP dan MAPEP .

3.4.4. Pemodelan dengan metode hibrida ARIMAX-NN

Pemodelan hibrida ARIMAX-NN dilakukan untuk memprediksi jumlah penumpang udara dan kargo di Indonesia dengan tahapan sebagai berikut:

- (1) Identifikasi variabel *dummy* berdasarkan komponen tren, musiman dan efek variasi kalender dalam hal ini *dummy* hari raya Idul Fitri.
- (2) Estimasi parameter dengan model regresi *time series*.
- (3) Modelkan residual hasil analisis regresi menggunakan ARIMA Box-Jenkins.
- (4) Cek signifikansi parameter model ARIMAX.
- (5) Cek residual dari model ARIMAX yang terbentuk apakah sudah mencapai kondisi *white noise* dan berdistribusi normal.
- (6) Peramalan model ARIMAX:

$$Y_t^{(1)} = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} N_t.$$

- (7) Hitung residual dari model ARIMAX
- (8) Residual ARIMAX digunakan sebagai input model NN.
- (9) Jumlah *neuron* pada *input layer* ditentukan sebanyak *lag* yang signifikan.
- (10) Penentuan jumlah *neuron* pada *hidden layer* untuk pemodelan diawali dengan 1 (satu) *hidden neuron*. Kemudian *neuron* pada *hidden layer* diperbarui

hingga 10 *neuron* kemudian di analisis nilai MAPEp sebagai dasar pemilihan model NN terbaik.

- (11) Tentukan fungsi aktivasi.
- (12) Pembelajaran jaringan untuk mendapatkan model FFNN.
- (13) Peramalan NN:

$$\hat{N}_t^{(2)} = f^0 \left[\sum_{j=1}^q \left\{ w_j^0 f_j^h \left(\sum_{i=1}^p w_{ij}^h N_{t-i} + b_j^h \right) + b^0 \right\} \right].$$

- (14) Peramalan model hibrida TSR-NN:

$$\hat{Y}_t = \hat{Y}_t^{(1)} + \hat{N}_t^{(2)}.$$

- (15) Hitung nilai RMSEP dan MAPEP.

3.4.5. Pemodelan dengan Metode hibrida ARIMAX-SVR

Pemodelan hibrida ARIMAX-SVR dilakukan untuk memprediksi jumlah penumpang udara dan kargo di Indonesia dengan tahapan sebagai berikut:

- (1) Pemodelan ARIMAX berdasarkan langkah-langkah pada bagian 3.4.4 tahap (1) s/d (7). Sehingga diperoleh model ARIMAX:

$$Y_t^{(1)} = \delta t + \sum_{m=1}^M \beta_m S_{m,t} + \sum_{g=1}^G \gamma_g V_{g,t} + \sum_{g=1}^G \varphi_g V_{g,t-1} + \sum_{g=1}^G \vartheta_g V_{g,t+1} + \frac{\theta_q(B) \Theta_Q(B^s)}{\phi_p(B) \Phi_P(B^s) (1-B)^d (1-B^s)^D} N_t.$$

- (2) Residual ARIMAX digunakan sebagai input NN
- (3) Penentuan fungsi kernel
- (4) Penentuan nilai-nilai parameter kernel, C dan *epsilon* untuk optimasi *hyperplane* pada data *training*.
- (5) Pemilihan nilai parameter terbaik menggunakan metode *grid-search*.
- (6) Peramalan SVR dengan nilai parameter terbaik:

$$\hat{N}_t^{(2)} = \sum_{i=i}^n (\hat{\alpha}_i - \hat{\alpha}_i^*) \exp \left(-\frac{\|N_i - N_{i^*}\|^2}{2\sigma^2} \right) + b$$

dengan $N_i = [N_{t-1} \ N_{t-2} \ \dots \ N_{t-p}]$ dan $N_{i^*} = [N_{t-2} \ N_{t-3} \ \dots \ N_{t-(p+1)}]$.

- (7) Peramalan model hibrida TSR-SVR:


$$\hat{Y}_t = \hat{Y}_t^{(1)} + \hat{N}_t^{(2)}.$$

(8) Hitung nilai RMSEP dan MAPEP.


3.4.6. Analisis Kinerja Peramalan

Untuk mengetahui kinerja peramalan dilakukan perbandingan nilai RMSEP dan MAPEP dari pemodelan dengan metode hibrida TSR-NN, TSR-SVR, ARIMAX-NN, dan ARIMAX-SVR. Setelah diperoleh model terbaik maka kemudian dilakukan estimasi peramalan hingga bulan Desember tahun 2018.


Adapun tahapan analisis tersebut dapat digambarkan dalam diagram alir pada Gambar 3.1. Ilustrasi pembentukan model hibrida TSR-NN dan ARIMAX-NN ditampilkan pada Gambar 3.2. Sedangkan ilustrasi pembentukan model hibrida TSR-SVR dan ARIMAX-SVR ditampilkan pada Gambar 3.3.



Gambar 3.1 Diagram Alir Tahapan Analisis



Gambar 3.2 Ilustrasi Pembentukan Model Hibrida TSR-NN dan ARIMAX-NN



Gambar 3.3 Ilustrasi Pembentukan Model Hibrida TSR-SVR dan ARIMAX-SVR


BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini akan dibahas secara rinci hasil analisis penelitian di tiga bandara Indonesia yaitu Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai dan Bandara Juanda. Pemodelan data penumpang dan kargo dilakukan dengan menggunakan analisis *time series* univariat yaitu model regresi *time series* (TSR), ARIMAX, hibrida TSR-NN, hibrida TSR-SVR, hibrida ARIMAX-NN, dan hibrida ARIMAX-SVR.

4.1 Karakteristik Data Penumpang dan Kargo


Data yang akan dianalisis pada ketiga bandara internasional terbesar di Indonesia yaitu Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai dan Bandara Juanda berada dalam rentang waktu bulan Januari 2001 sampai dengan Agustus 2017. Perkembangan jumlah penumpang udara dan volume kargo secara kumulatif ketiga bandara tersebut pada ditunjukkan pada Gambar 4.1.



Gambar 4.1 Plot Time Series Data Penumpang yang Berangkat (a) dan yang Datang (b), serta Kargo yang Dimuat (c) dan yang Dibongkar (d) Kumulatif Tiga Bandara Internasional

Berdasarkan pada *plot time series* Gambar 4.1, perkembangan data jumlah penumpang dan volume kargo di ketiga bandara tersebut memiliki pola kenaikan dari tahun ke tahun. Pergerakan penumpang juga memiliki pola musiman, dimana terjadi pergerakan yang tinggi pada bulan Juli dan Desember, yang disebabkan adanya libur awal tahun ajaran baru di bulan Juli serta perayaan Natal dan Tahun Baru di bulan Desember.

Plot tersebut menunjukkan bahwa kejadian hari raya Idul Fitri memberikan efek peningkatan pada data tersebut. Untuk mengetahui apakah terdapat pengaruh minggu terjadinya hari raya Idul Fitri, maka dilakukan perbandingan rata-rata penumpang dan kargo secara visual yang ditunjukkan Gambar 4.2, pada bulan terjadinya hari raya Idul Fitri, satu bulan sebelum hari raya Idul dan satu bulan setelah hari raya Idul Fitri.



Gambar 4.2 Pengaruh Minggu Terhadap Rata-rata Penumpang yang Berangkat (a) dan yang Datang (b), serta Kargo yang Dimuat (c) dan yang Dibongkar (d) di Ketiga Bandara Internasional

Gambar 4.2 menjelaskan bahwa pengaruh hari raya Idul Fitri yang terjadi di minggu yang berbeda akan berpengaruh terhadap peningkatan penumpang dan kargo yang berbeda. Untuk data jumlah penumpang baik yang berangkat dan datang di ketiga bandara tersebut, apabila hari raya Idul Fitri terjadi pada minggu pertama


dan kedua maka rata-rata penumpang tinggi pada bulan terjadinya hari raya Idul Fitri. Namun apabila hari raya Idul Fitri terjadi pada minggu ketiga dan keempat maka rata-rata penumpang pada saat hari raya Idul Fitri tidak lebih tinggi dibandingkan satu bulan sebelum dan satu bulan setelah hari raya Idul Fitri.

Sedangkan pada data kargo, apabila hari raya Idul Fitri terjadi pada minggu pertama, kedua, ketiga dan keempat maka rata-rata penumpang tinggi pada 1 bulan sebelum terjadinya hari raya Idul Fitri dan 1 bulan setelah hari raya Idul Fitri. Oleh karena itu, untuk pemodelan data kargo lebih sulit diprediksi dibandingkan dengan pemodelan data penumpang. Sehingga dalam pemodelan data penumpang dan kargo di ketiga bandara tersebut diperlukan model variasi kalender yang memasukkan pengaruh satu bulan sebelum hari raya Idul Fitri, minggu terjadinya hari raya Idul Fitri dan satu bulan setelah hari raya Idul Fitri.

4.1.1 Karakteristik Data di Bandara Internasional Soekarno Hatta

Representasi visual data *time series* untuk data jumlah penumpang dan volume kargo di Bandara Soekarno Hatta disajikan pada Gambar 4.3. perkembangan memiliki tren positif dengan tingkat pergeseran pada awal tahun 2001. Namun pada data kargo domestik yang dibongkar di Bandara Soekarno Hatta terjadi perubahan tren penurunan yang diawali pada bulan april 2014. Menurut data PT Angkasa Pura II, penurunan volume kargo udara tersebut karena terhambatnya pengiriman barang domestik ke Bandara Soekarno Hatta seiring dengan meletusnya gunung Sinabung Sumatera Utara dan Gunung Kelud Jawa Timur.

Gambar 4.3 juga menunjukkan bahwa data *in-sample* yang digunakan pada semua variabel penelitian yang dianalisis di Bandara Soekarno Hatta adalah data bulan Januari 2001 sampai dengan Agustus 2016 dan data *out-sample* yang digunakan adalah data bulan September 2016 sampai dengan Desember 2017. Data *out-sample* yang digunakan sebanyak 12 bulan terakhir dikarenakan data tersebut cenderung stabil. Sedangkan analisis statistika deskriptif dari jumlah penumpang dan kargo ditampilkan pada Tabel 4.1.



Gambar 4.3. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Soekarno Hatta.


Tabel 4.1 Statistika Deskriptif Data Penumpang dan Kargo Bandara Soekarno Hatta

Data	Mean	Standar Deviasi	Minimum	Maksimum
Penumpang (dalam Orang):				
Domestik berangkat	1.142.574	502.513	205.784	2.109.734
Domestik datang	1.391.283	621.293	266.760	2.761.644
Internasional berangkat	364.958	143.442	108.651	711.289
Internasional datang	363.836	136.318	28.744	718.210
Kargo (dalam Ton):				
Domestik dimuat	12.940	4.639	5.102	22.628
Domestik dibongkar	5.614	1.785	2.486	10.822
Internasional dimuat	9.692	2.579	5.723	16.826
Internasional dibongkar	9.295	3.069	4.561	18.350

Tabel 4.1 menjelaskan bahwa pergerakan penumpang yang ada di Bandara Soekarno Hatta didominasi oleh kedatangan penumpang domestik dengan rata-rata perbulan sebanyak 1.142.574 penumpang. Sedangkan untuk pergerakan penumpang internasional didominasi oleh jalur keberangkatannya dengan rata-rata perbulan sebanyak 364.958 penumpang. Selain penumpang, pergerakan kargo domestik yang dimuat di Bandara Soekarno Hatta juga memegang peranan yang penting. Karena Bandara Soekarno Hatta merupakan bandar udara terbesar yang berfungsi sebagai pintu gerbang perdagangan melalui angkutan udara. Rata-rata sebulan volume kargo domestik yang dimuat dari bandara tersebut berkisar sekitar 12.940 ton. Adapun jenis komoditi ekspor terbesar yang diekspor melalui Bandara Soekarno Hatta antara lain tekstil, makanan olahan, ikan dan udang segar/beku, kayu olahan, buah-buahan, tanaman hidup, dan lainnya.

4.1.2 Karakteristik Data di Bandara Internasional I Gusti Ngurah Rai

Secara visual perkembangan jumlah penumpang dan volume kargo di Bandara I Gusti Ngurah Rai dapat dilihat pada Gambar 4.4. Namun pada data kargo di Bandara I Gusti Ngurah Rai pada 12 bulan terakhir terjadi peningkatan yang signifikan. Hal tersebut terjadi karena adanya penambahan rute penerbangan baik domestik hingga internasional, yang mengakibatkan terjadi peningkatan pengiriman volume perdagangan dari dan menuju Bali.



Gambar 4.4. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara I Gusti Ngurah Rai.

Dasar dari penentuan data *in-sample* dan *out-sample* di Bandara I Gusti Ngurah Rai adalah *plot time series* pada Gambar 4.4. Plot time series tersebut

menunjukkan untuk semua data penumpang udara serta data kargo domestik yang dibongkar di Bandara I Gusti Ngurah Rai menggunakan data *in-sample* dari bulan Januari 2001 hingga Agustus 2016 dan data *out-sample* bulan September 2016 hingga Desember 2017. Data *out-sample* yang digunakan sebanyak 12 bulan terakhir dikarenakan data tersebut cenderung stabil. Namun untuk data kargo domestik yang dimuat, data kargo internasional yang dimuat, dan data kargo internasional yang dibongkar di bandara ini menggunakan *in-sample* data bulan Januari 2001 hingga Agustus 2015. Adapun data *out-sample* menggunakan data bulan September 2015 hingga Desember 2017. Data *out-sample* yang digunakan sebanyak 24 bulan terakhir dikarenakan pada data 12 bulan terakhir terjadi pola peningkatan yang tajam. Statistika deskriptif data penumpang dan kargo di Bandara I Gusti Ngurah Rai ditampilkan pada Tabel 4.2.

Tabel 4.2 Statistika Deskriptif Data Penumpang dan Kargo Bandara I Gusti Ngurah Rai

Data	Mean	Standar Deviasi	Minimum	Maksimum
Penumpang (dalam Orang):				
Domestik berangkat	224.510	120.444	52.169	547.576
Domestik datang	232.032	120.610	58.680	507.394
Internasional berangkat	224.053	116.645	14.774	621.580
Internasional datang	224.041	110.144	44.520	554.840
Kargo (dalam Ton):				
Domestik dimuat	610	256	69	1.852
Domestik dibongkar	1046	330	165	1.848
Internasional dimuat	2257	637	705	3.873
Internasional dibongkar	762	417	191	2.834

Dari Tabel 4.2 terlihat bahwa jumlah pergerakan penumpang yang ada di Bandara I Gusti Ngurah Rai didominasi oleh kedatangan penumpang domestik dengan rata-rata perbulan sebanyak 232.032 penumpang. Sedangkan untuk pergerakan penumpang internasional didominasi oleh jalur keberangkatannya dengan rata-rata perbulan sebanyak 224.053 penumpang. Bandara I Gusti Ngurah Rai merupakan bandara internasional yang menjadi pintu masuk wisatawan dari mancanegara dan domestik melalui jalur udara ke Bali. Sedangkan untuk kargo didominasi oleh volume kargo internasional yang dimuat dengan rata-rata perbulan sekitar 2.257 ton.


4.1.3 Karakteristik di Bandara Internasional Juanda

Secara visual pergerakan penumpang dan kargo di Bandara Internasional Juanda dapat dilihat pada Gambar 4.5. *Plot time series* tersebut juga menunjukkan bahwa penentuan data *in-sample* yang digunakan dalam pemodelan data penumpang dan kargo di Bandara Juanda adalah data bulan Januari 2001 sampai dengan Agustus 2016. Sedangkan data *out-sample* yang digunakan adalah data bulan September 2016 sampai dengan Desember 2017. Data *out-sample* yang digunakan sebanyak 12 bulan terakhir dikarenakan data tersebut cenderung stabil. Analisis statistika deskriptif dari jumlah penumpang dan volume kargo di Bandara Juanda dapat dilihat pada Tabel 4.3.

Tabel 4.3 Statistika Deskriptif Data Penumpang dan Kargo Bandara Juanda

Data	Mean	Standar Deviasi	Minimum	Maksimum
Penumpang (dalam Orang):				
Domestik berangkat	394.397	181.266	74.986	88.954
Domestik datang	484.081	217.597	100.348	889.548
Internasional berangkat	47.189	20.625	12.131	98.232
Internasional datang	5.069	20.780	12.258	99.016
Kargo (dalam Ton):				
Domestik dimuat	276	1.079	822	5204
Domestik dibongkar	2.208	722	830	3961
Internasional dimuat	676	196	200	1104
Internasional dibongkar	680	270	84	1981

Tabel 4.3 menunjukkan bahwa jumlah pergerakan penumpang yang ada di Bandara Juanda didominasi oleh kedatangan penumpang domestik dengan rata-rata perbulan sebanyak 484.081 penumpang. Sedangkan untuk pergerakan penumpang internasional didominasi oleh jalur keberangkatannya dengan rata-rata perbulan sebanyak 47.189 penumpang. Bandara Internasional Juanda adalah bandara tersibuk kedua di Indonesia setelah Bandara Internasional Soekarno Hatta berdasarkan pergerakan pesawat dan penumpang. Sedangkan untuk pergerakan kargo udara didominasi oleh volume kargo domestik yang dibongkar dengan rata-rata perbulan sekitar 2.208 ton.




Gambar 4.5. Perkembangan data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Juanda.

4.2 Pemodelan Bandara Internasional Soekarno Hatta

Tahapan pemodelan yang dilakukan untuk data penumpang dan kargo di Bandara Internasional Soekarno Hatta terdiri dari pemodelan tahap pertama dan pemodelan tahap kedua. Pemodelan tahap pertama menggunakan model TSR dan ARIMAX. Sedangkan pemodelan tahap kedua dengan metode peramalan hibrida yaitu TSR-NN, ARIMAX-NN, TSR-SVR, dan ARIMAX-SVR menggunakan input residual model tahap pertama. Dari keempat model tersebut diperoleh model terbaik, kemudian diperoleh angka prediksi 2018 dari model terbaiknya.

4.2.1 Pemodelan *Time Series Regression* (TSR)

Pada pemodelan regresi *time series*, tahapan pertama yang dilakukan adalah pengujian asumsi residual yang meliputi *white noise* dan distribusi normal. Data jumlah penumpang dan kargo di Bandara Soekarno Hatta dibagi menjadi dua, yaitu data *in-sample* yang terdiri dari data bulan Januari 2001 hingga Agustus 2016 dan data *out-sample* yang terdiri dari bulan September 2016 hingga Agustus 2017. Tahapan pertama yang dilakukan untuk data jumlah penumpang domestik yang berangkat adalah uji residual *white noise*. Uji residual *white noise* dapat dilakukan menggunakan plot ACF seperti Gambar 4.6. Apabila terdapat *lag* yang keluar dari batas maka *lag* tersebut di masukkan dalam model, Kemudian diregresikan kembali sampai mendapatkan residual pada plot ACF yang *white noise* (*lag* ACF tidak ada yang keluar dari batas).



Gambar 4.6 Plot ACF sebelum *white noise* (a) dan plot ACF sesudah *white noise* (b) pada data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta

Setelah memenuhi asumsi residual *white noise*, tahap selanjutnya adalah uji estimasi parameter dan pengujian signifikansi parameter. Model dengan parameter yang signifikan diperiksa kembali jika memenuhi asumsi residual *white noise* maka

tahap selanjutnya melakukan uji asumsi residual berdistribusi normal menggunakan uji Kolmogorov-Smirnov. Namun data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta belum memenuhi asumsi tersebut karena diperoleh hasil *p-value* kurang dari taraf uji $\alpha = 0,05$. Salah satu solusi agar asumsi residual berdistribusi normal terpenuhi maka dilakukan deteksi *outlier*. Deteksi *outlier* pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta dijelaskan pada Tabel 4.4.

Tabel 4.4 Deteksi *Outlier* Data Jumlah Penumpang Domestik yang Berangkat

No Observasi	Tipe	Estimasi	Chi-Square	<i>P-value</i>
76	Additive	255.619,6	17,39	<0,0001
88	Additive	-205.572,5	12,31	0,0005
126	Additive	217.261,3	13,24	0,0003
152	Additive	191.091,6	12,28	0,0009
156	Additive	233.006,6	14,79	0,0001
158	Additive	-250.230,7	17,05	<0,0001
169	Additive	-250.994,1	17,11	<0,0001
171	Additive	-159.617,5	7,85	0,0051
177	Additive	-201.348,3	12,28	0,0005

Setelah *outlier* tersebut dimasukkan ke dalam model diperoleh nilai *p-value* uji Kolmogorov-Smirnov sebesar 0,1164 atau lebih dari taraf uji $\alpha = 0,05$, yang berarti asumsi distribusi normal pada residual data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta telah terpenuhi. Sehingga dapat disimpulkan adanya ketidaknormalan dari residual model disebabkan oleh adanya *outlier*. Adapun penjelasan terjadinya *outlier* akan dijelaskan pada Tabel 4.5.

Tabel 4.5 Penjelasan Data Terjadinya *Outlier*

Data ke-	Tipe	Bulan, Tahun	Kejadian
76	Additive	April, 2007	Terjadi peningkatan jumlah penumpang yang belum diketahui penyebabnya
88	Additive	April, 2008	Efek letusan gunung Egon NTT diawali tanggal 15 April
126	Additive	Juni, 2011	Libur awal tahun ajaran baru
152	Additive	Agustus, 2013	Hari Raya Idul Fitri
156	Additive	Desember, 2013	Libur Hari Natal dan Tahun Baru
158	Additive	Februari, 2014	Efek letusan gunung Kelud dimulai tanggal 2 Feb 2014 dan letusan besarnya tanggal 13 Feb 2014
169	Additive	Januari, 2015	Terjadi penurunan jumlah penumpang pasca Natal dan Tahun Baru
171	Additive	Maret, 2015	Efek letusan gunung Sinabung SUMUT sejak tanggal 5 Maret
177	Additive	September, 2015	Efek aktivitas tinggi luapan erupsi gunung Sinabung pada bulan september

Sedangkan hasil signifikansi parameter pada data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta ditampilkan pada Tabel 4.6.

Tabel 4.6 Hasil pengujian Signifikansi Parameter Untuk Data Jumlah Penumpang Domestik yang Berangkat

Variabel	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
t	1.871,2	482,52	3,88	0,0002
S1	65.295,6	23435,6	2,79	0,0061
S3	124.411,8	21784,2	5,71	<0,0001
S4	53.030,8	21262,2	2,49	0,0138
S5	98.039,9	22734,1	4,29	<0,0001
S6	94528,6	22023,1	4,29	<0,0001
S7	218.167,8	24024,9	9,08	<0,0001
S8	72.143,2	22886,7	3,15	0,0020
S9	102.869,7	22334,7	4,61	<0,0001
S10	130.727,2	22477,5	5,82	<.0,0001
S11	106.740,3	22672,3	4,71	<0,0001
S12	144.340,5	24336,5	5,93	<0,0001
V_{1,t-1}	-193.870,2	30184,0	-6,42	<0,0001
V_{2,t-1}	-133.515,8	38404,0	-3,48	0,0007
V_{3,t-1}	-73.477,7	33406,1	-2,20	0,0294
V_{2,t}	102.287,9	38720,2	2,64	0,0092
V_{4,t}	-127.464,7	39567,0	-3,22	0,0016
V_{2,t+1}	-99.419,7	38833,9	-2,56	0,0115
Y_{1,1,t-1}	0,52	0,049	10,50	<0,0001
Y_{1,1,t-5}	0,21	0,05	4,08	<0,0001
Y_{1,1,t-12}	0,34	0,06	6,13	<0,0001
Y_{1,1,t-13}	-0,29	0,06	-5,04	<0,0001
I_t⁽⁷⁶⁾	261.248,6	66044,6	3,96	0,0001
I_t⁽⁸⁸⁾	-205.098,1	67688,6	-3,03	0,0029
I_t⁽¹²⁶⁾	229.903,9	65412,6	3,51	0,0006
I_t⁽¹⁵²⁾	269.059,7	66460,2	4,05	<0,0001
I_t⁽¹⁵⁶⁾	250.327,5	67263,2	3,72	0,0003
I_t⁽¹⁶⁹⁾	-258.836,5	67163,2	-3,85	0,0002
I_t⁽¹⁷¹⁾	-237.060	67.404,2	-3,52	0,0006
I_t⁽¹⁷⁷⁾	-201.792,4	67847,0	-2,97	0,0034

Dengan cara yang sama akan diperoleh model regresi *time series* untuk ketujuh data lainnya. Adapun ringkasan pemeriksaan diagnosa untuk keseluruhan data penumpang dan kargo Bandara Soekarno Hatta dijelaskan pada Tabel 4.7.

Tabel 4.7. Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara Soekarno Hatta

Data	White Noise	Data Outlier ke-	Jenis Outlier	Uji KS (p-value)
Penumpang:				
Domestik berangkat	YA	76, 88, 126, 152, 156, 158, 169, 171, 177	Additive	0,1164
Domestik datang	YA	76, 128, 129, 157, 158, 160, 163, 168, 170, 177	Additive	>0,1500
Internasional berangkat	YA	37, 96, 126, 147, 151	Additive	>0,1500
Internasional datang	YA	108, 158, 164	Additive	0,0689
Kargo:				
Domestik dimuat	YA	48, 107, 124 131, 134 151, 152	Additive	>0,1500
Domestik dibongkar	YA	72, 73, 79, 135, 136, 147	Additive	0,0918
Internasional dimuat	YA	125, 135, 146, 149, 155 165, 188	Additive	0.089
Internasional dibongkar	YA	131, 154, 165, 166	Additive	0,1083

Setelah tahapan pemeriksaan diagnosa dan signifikansi parameter terpenuhi maka model regresi *time series* secara matematis dapat dituliskan sebagai berikut:

Data penumpang:

$$\begin{aligned} \hat{Y}_{1,1,t}^{(1)} = & 1871,2t + 65295,6S_1 + 124411,8S_3 + 53030,8S_4 + 98039,9S_5 + 94528,6S_6 + \\ & 218167,8S_7 + 72143,2S_8 + 102869,7S_9 + 130727,2S_{10} + 106740,3S_{11} + \\ & 144340,5S_{12} - 193870,2V_{1,t-1} - 133515,8V_{2,t-1} - 73477,7V_{3,t-1} + 102287,9V_{2,t} - \\ & 127464,7V_{4,t} - 99419,7V_{2,t+1} + 0,52Y_{1,1,t-1} + 0,21Y_{1,1,t-5} + 0,34Y_{1,1,t-12} - \\ & 0,29Y_{1,1,t-13} + 261248,6I_t^{(76)} - 205098,1I_t^{(88)} + 229903,9I_t^{(126)} + 269059,7I_t^{(152)} + \\ & 250327,5I_t^{(156)} - 270644,9I_t^{(158)} - 258836,5I_t^{(169)} - 21792,4I_t^{(171)} - 237060I_t^{(177)} \end{aligned} \quad (4.1)$$

$$\begin{aligned} \hat{Y}_{2,1,t}^{(1)} = & 1028,4t - 118075,8S_2 + 102923,1S_3 + 57529,2S_4 + 89995,3S_5 + 121232,9S_6 + \\ & 143542,5S_7 - 251919,7V_{1,t-1} + 209929,1V_{1,t} + 127660V_{2,t} + 128507,5V_{3,t+1} + \\ & 231785,4V_{4,t+1} + 0,53Y_{2,1,t-1} + 0,29Y_{2,1,t-2} + 0,11Y_{2,1,t-12} + 322468,9I_t^{(76)} - \\ & 321435,6I_t^{(128)} - 447359,3I_t^{(157)} - 415631,8I_t^{(158)} - 269607,3I_t^{(160)} - \\ & 435238,5I_t^{(163)} - 291462,5I_t^{(169)} - 251750,4I_t^{(170)} - 469035,1I_t^{(177)} \end{aligned} \quad (4.2)$$

$$\begin{aligned} \hat{Y}_{3,1,t}^{(1)} = & 243,81t + 24012,8S_3 + 30001,8S_5 + 27048,1S_6 + 21594,6S_7 + 27139,8S_8 + \\ & 67073,3S_{12} + 28368,8V_{1,t+1} - 64433,4V_{4,t+1} + 0,35Y_{3,1,t-1} + 0,24Y_{3,1,t-3} + \\ & 0,33Y_{3,1,t-12} + 60279,7I_t^{(37)} - 83679,2I_t^{(96)} + 80025,5I_t^{(126)} + 68893,8I_t^{(147)} - \\ & 61053,9I_t^{(151)} \end{aligned} \quad (4.3)$$

$$\begin{aligned} \hat{Y}_{4,1,t}^{(1)} = & 254,26t + 44071,4S_1 - 28163,5S_2 + 42183,2S_3 + 32433,3S_5 + 33742,3S_6 + \\ & 75406,4S_7 - 46055V_{1,t-1} + 41328,2V_{2,t} - 56973,2V_{4,t} - 42440,2V_{2,t+1} + \\ & 77784,5V_{4,t+1} + 0,37Y_{4,1,t-1} + 0,18Y_{4,1,t-3} + 0,15Y_{4,1,t-9} + 0,21Y_{4,1,t-12} + \\ & 105234,1I_t^{(108)} - 135012,9I_t^{(164)} - 69320,6I_t^{(158)} \end{aligned} \quad (4.4)$$

Data kargo:

$$\begin{aligned}\hat{Z}_{1,1,t}^{(1)} = & 22,36t + 1266,5S_1 + 1821,4S_3 + 1265,3S_4 + 2377,5S_5 + 2153,8S_6 + 1597S_7 + \\ & 1749,6S_8 + 1289S_9 + 2041,4S_{10} + 1746,3S_{11} + 3207,1S_{12} + 1971,3V_{2,t-1} + \\ & 1043V_{3,t-1} - 3182,3V_{1,t} - 2265V_{2,t} - 2327,5V_{3,t} + 1856,6V_{2,t+1} + 0,37Z_{1,1,t-1} + \\ & 0,35Z_{1,1,t-3} - 3641,8I_t^{(48)} - 4725I_t^{(107)} + 4776,9I_t^{(124)} + 3733,5I_t^{(131)} - \\ & 2842,3I_t^{(134)} + 3075,4I_t^{(151)} - 2995,3I_t^{(152)}\end{aligned}\quad (4.5)$$

$$\begin{aligned}\hat{Z}_{2,1,t}^{(1)} = & -781,03S_2 + 305,1S_{11} + 554S_{12} - 1151,4V_{1,t} - 1187,5V_{2,t} + 0,47Z_{2,1,t-1} + \\ & 0,33Z_{2,1,t-2} + 0,20Z + 4077,3I_t^{(72)} - 2091,3I_t^{(73)} + 2117,5I_t^{(79)} - 2919,7I_t^{(135)} + \\ & 3122,4I_t^{(136)} - 1958,3I_t^{(147)}\end{aligned}\quad (4.6)$$

$$\begin{aligned}\hat{Z}_{3,1,t}^{(1)} = & 15,35t + 2767,2S_1 + 1668,9S_2 + 3915,8S_3 + 2149,4S_4 + 2707S_5 + 1433,2S_6 + \\ & 2640S_7 + 2397,9S_8 + 2927,8S_9 + 3143,8S_{10} + 2883,1S_{11} + 2338,3S_{12} - \\ & 1196,5V_{1,t-1} - 1454,3V_{1,t} + 0,48Z_{3,1,t-1} + 0,11Z_{3,1,t-13} - 3324,4I_t^{(125)} - \\ & 4451,1I_t^{(135)} + 4658,4I_t^{(146)} + 3304,1I_t^{(149)} - 3718,4I_t^{(165)} - 5369,5I_t^{(188)}\end{aligned}\quad (4.7)$$

$$\begin{aligned}\hat{Z}_{4,1,t}^{(1)} = & 15,56t + 2139S_1 + 1569,2S_2 + 3716,1S_3 + 2819,4S_4 + 3608,3S_5 + 2157,3S_6 + \\ & 2018,5S_7 + 2423,5S_8 + 3244,5S_9 + 2804,7S_{10} + 2083,7S_{11} + 2010,4S_{12} - \\ & 2659,5V_{2,t} - 1482V_{3,t} - 1873,3V_{4,t} + 0,57Z_{4,1,t-1} + 7445,7,4I_t^{(131)} - 7131,9I_t^{(154)} - \\ & 5663,2I_t^{(165)} + 6878,6I_t^{(166)}.\end{aligned}\quad (4.8)$$

Setelah diperoleh persamaan model TSR untuk masing-masing data penumpang dan kargo di Bandara Soekarno Hatta, maka dilakukan evaluasi kebaikan model menggunakan kriteria RMSE dan MAPE untuk data *training* dan *testing* pada Tabel 4.8.


Tabel 4.8. Hasil Peramalan Model TSR di Bandara Soekarno Hatta

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	57.027,58	4,31	135.754,47	6,80
Domestik datang	87.886,65	5,78	166.945,57	6,39
Internasional berangkat	25.683,27	6,26	41.627,03	4,99
Internasional datang	30.003,14	9,79	58.849,01	7,22
Kargo:				
Domestik dimuat	1.009,83	6,47	2.394,36	11,54
Domestik dibongkar	593,26	7,47	1.432,65	28,77
Internasional dimuat	1.302,80	10,66	1.720,78	10,51
Internasional dibongkar	1.476,17	12,43	2.408,68	16,20

4.2.2 Pemodelan ARIMAX

Selanjutnya adalah pemodelan ARIMAX yang mengandung komponen tren, musiman serta efek variasi kalender untuk data penumpang dan kargo di

Bandara Internasional Soekarno Hatta. Tahap pertama pemodelan ARIMA variasi kalender adalah data dimodelkan terlebih dahulu dengan model regresi *time series*. Kemudian residual dari hasil pemodelan *time series* tersebut dimodelkan dengan ARIMA berdasarkan pola ACF dan PACF. Gambar 4.7 menunjukkan pola ACF dan PACF untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta.



Gambar 4.7 Plot ACF dan PACF residual hasil regresi *time series* pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta

Berdasarkan dengan pola ACF dan PACF dari Gambar 4.7 tersebut maka diperoleh model ARIMAX $([1,2,5],0,0)(1,0,0)^{12}$. Tahapan selanjutnya adalah melakukan pengujian asumsi residual *white noise* dengan menggunakan uji *Ljung-Box* untuk sampel ACF komponen residual seperti pada Tabel 4.9.

Tabel 4.9 Hasil Uji *White Noise* Model ARIMAX Data Jumlah Penumpang Domestik yang Berangkat dari Bandara Soekarno Hatta

<i>Lag</i>	<i>Chi-Square</i>	<i>DF</i>	<i>P-value</i>
6	0,29	2	0,8662
12	11,86	8	0,1573
18	18,96	14	0,1665
24	23,15	20	0,2816
30	30,17	26	0,2608
36	43,39	32	0,0862

Berdasarkan Tabel 4.9 tersebut, terlihat bahwa asumsi *white noise* sudah terpenuhi karena pada semua *lag* dengan nilai *p-value* kurang dari taraf uji $\alpha = 0,05$. Setelah memenuhi asumsi tersebut, maka tahap selanjutnya adalah uji estimasi parameter dan pengujian signifikansi parameter. Model dengan parameter yang signifikan diperiksa kembali jika memenuhi asumsi *white noise* maka selanjutnya melakukan pengecekan asumsi residual berdistribusi normal dengan menggunakan uji Kolmogorov-Smirnov. Salah satu cara untuk mengatasi data tidak

memenuhi asumsi normalitas adalah dengan deteksi *outlier*. Hasil pengujian residual model ARIMAX data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta setelah dilakukan deteksi *outlier* diperoleh nilai *p-value* lebih dari taraf uji $\alpha = 0,05$ artinya asumsi distribusi normal telah terpenuhi. Sedangkan hasil signifikansi parameter model ARIMAX untuk data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta ditampilkan Tabel 4.10.

Tabel 4.10 Hasil Pengujian Signifikansi Parameter untuk Data Jumlah Penumpang Domestik yang Berangkat

Variabel	Estimasi	Standar Error	<i>t-value</i>	<i>P-value</i>
ϕ_1	0,42949	0,07781	5,52	<0,0001
ϕ_2	0,22946	0,0806	2,85	0,005
ϕ_5	0,22396	0,06894	3,25	0,0014
Φ_1	0,33813	0,08555	3,95	0,0001
t	9210,7	597,372	15,42	<0,0001
S1	155608	31274,5	4,98	<0,0001
S3	152006	31979,3	4,75	<0,0001
S4	103085	34499,8	2,99	0,0032
S5	202010	37343,6	5,41	<0,0001
S6	198583	37863,1	5,24	<0,0001
S7	280623	34999,2	8,02	<0,0001
S8	184347	36292,7	5,08	<0,0001
S9	129225	35574	3,63	0,0004
S10	185820	38514,7	4,82	<0,0001
S11	189485	37922	5	<0,0001
S12	287313	34831,7	8,25	<0,0001
$V_{1,t-1}$	-156680	31227,6	-5,02	<0,0001
$V_{2,t}$	80504,8	37999,6	2,12	0,0356
$V_{4,t}$	-188801	38693,6	-4,88	<0,0001
$I_t^{(76)}$	287038	65698,3	4,37	<0,0001
$I_t^{(156)}$	140585	65466,3	2,15	0,0332

Selanjutnya dengan tahapan yang sama akan diperoleh model ARIMAX dengan komponen tren, musiman dan efek variasi kalender untuk semua data penumpang dan kargo di Bandara Soekarno Hatta. Adapun ringkasan hasil pengujian asumsi model ARIMAX tersebut dijabarkan pada Tabel 4.11.

Tabel 4.11 Ringkasan Hasil Pengujian Asumsi Model ARIMAX di Bandara Soekarno Hatta

Data	Model ARIMAX	White Noise	Data Additive Outlier ke-	Uji KS (p-value)
Penumpang:				
Domestik berangkat	$([1,2,5],0,0)(1,0,0)^{12}$	YA	76, 156	$>0,1500$
Domestik datang	$(2,0,0)(1,0,0)^{12}$	YA	76, 160	$>0,1500$
Internasional berangkat	$(1,0,0)(1,0,0)^{12}$	YA	28, 60, 130, 142, 152, 176, 160	0,1148
Internasional datang	$([1,3,9],0,0)(2,0,0)^{12}$	YA	24, 61	$>0,1500$
Kargo:				
Domestik dimuat	$([1,3],0,0)$	YA	79, 107, 124, 131, 151	$>0,1500$
Domestik dibongkar	$([1,2,8],0,0)$	YA	72, 74, 80, 107, 133, 147, 159	0,0774
Internasional dimuat	$(0,0,2)$	YA	87, 146, 155, 158, 188	0,0765
Internasional dibongkar	$(0,0,3)$	YA	165	0,1095

Apabila uji asumsi residual dan signifikansi parameter telah terpenuhi maka model regresi ARIMAX secara matematis dapat dituliskan sebagai berikut:

Data penumpang:

$$Y_{1,1,t}^{(1)} = 9210,7t + 155607,5S_1 + 152005,7S_3 + 103084,8S_4 + 202010S_5 + 198583,1S_6 + 280622,7S_7 + 184346,7S_8 + 129224,5S_9 + 185820,4S_{10} + 189484,9S_{11} + 287312,7S_{12} - 156680,2V_{1,t-1} + 80504,8V_{2,t} - 188800,9V_{4,t} + 287037,5I_t^{(76)} + 140584,5I_t^{(156)} + \frac{1}{(1+0,43B+0,23B^2+0,22B^5)(1+0,34B^{12})}N_{1,1,t} \quad (4.9)$$

$$Y_{2,1,t}^{(1)} = 11132t + 182175,7S_1 + 161257,9S_3 + 152947,6S_4 + 232837,9S_5 + 302892,1S_6 + 392474,4S_7 + 314869S_8 + 254165,8S_9 + 259858,2S_{10} + 264470,6S_{11} + 303092,4S_{12} - 249799,6V_{1,t-1} - 125372,7V_{2,t-1} - 339243,1V_{4,t} + 136993V_{3,t+1} + 287861,7I_t^{(76)} - 268757,3I_t^{(160)} + \frac{1}{(1+0,65B+0,23B^2)(1+0,35)}N_{2,1,t} \quad (4.10)$$

$$Y_{3,1,t}^{(1)} = 2058,9t + 156495,4S_1 + 161660,1S_2 + 173655,5S_3 + 152983,1S_4 + 159501,7S_5 + 179149,8S_6 + 175427,9S_7 + 178173,1S_8 + 162442S_9 + 141807,2S_{10} + 128172,1S_{11} + 208606,2S_{12} - 20437,9V_{2,t-1} - 19094,1V_{1,t} + 30512,2V_{1,t+1} - 32816,6V_{4,t+1} - 32816,6I_t^{(28)} + 53460,4I_t^{(60)} - 45649,9I_t^{(130)} + 51674I_t^{(142)} + 96399I_t^{(152)} - 57315,7I_t^{(160)} + 71213,9I_t^{(176)} + \frac{1}{(1+0,70B)(1+0,78B^{12})}N_{3,1,t} \quad (4.11)$$

$$Y_{4,1,t}^{(1)} = 1676, t + 233925,8S_1 + 152648,6S_2 + 220654,5S_3 + 201625,3S_4 + 204296,3S_5 + 221178,1S_6 + 266532,8S_7 + 206378,6S_8 + 187017,5S_9 + 182522,3S_{10} + 193284,8S_{11} + 208015,9S_{12} - 38515,5V_{1,t-1} + 23819,9V_{2,t} - 50853,2V_{4,t} - 204783,7I_t^{(24)} - 86510,2I_t^{(61)} + \frac{1}{(1+0,53B+0,17B^3+0,16B^9)(1+0,39B^{12}+0,37B^{23})}N_{4,1,t} \quad (4.12)$$

Data kargo:

$$Z_{1,1,t}^{(1)} = 74,53t + 5528,2S_1 + 4010,1S_2 + 5449,4S_3 + 5162,2S_4 + 5718,5S_5 + 6089S_6 + 5851,3S_7 + 5534,6S_8 + 5304,5S_9 + 6013,6S_{10} + 5734,3S_{11} + 6795S_{12} + \quad (4.13)$$

$$\begin{aligned}
& 1920,4V_{2,t-1} + 1128,8V_{3,t-1} - 3185,7V_{1,t} - 2139,6V_{2,t} - 1837,5V_{3,t} - 3354,6I_t^{(79)} - \\
& 4307,8I_t^{(107)} + 4351,5I_t^{(124)} + 4016,5I_t^{(131)} - 3424I_t^{(151)} + \frac{1}{(1+0,4B+0,37B^3)}N_{1,1,t} \\
Z_{2,1,t}^{(1)} = & 2947,9S_1 + 2197,5S_2 + 2602,9S_3 + 2627,2S_4 + 2788,0S_5 + 2816,9S_6 + 3004,3S_7 + \\
& 2868,1S_8 + 2848,1S_9 + 2742,3S_{10} + 2825,5S_{11} + 3254,6S_{12} - 962,89V_{1,t} - \\
& 746,5V_{2,t} - 516,84V_{3,t} + 4061,4I_t^{(72)} + 1430,2I_t^{(74)} + 2106,9I_t^{(80)} + 1164,8I_t^{(107)} + \\
& 1047,7I_t^{(133)} - 3420,5I_t^{(135)} + 1699,6I_t^{(147)} + 2387,6I_t^{(159)} + \\
& \frac{1}{(1+0,53B+0,24B^2+0,22B^8)}N_{2,1,t}
\end{aligned} \tag{4.14}$$

$$\begin{aligned}
Z_{3,1,t}^{(1)} = & 31,3t + 6729,4S_1 + 6020,3S_2 + 7261,8S_3 + 6799,1S_4 + 6892,9S_5 + 5739,5S_6 + \\
& 6210,9S_7 + 6298S_8 + 6525S_9 + 6979,5S_{10} + 6950,4S_{11} + 6442,6S_{12} + N_{3,1,t} - \\
& 0,51N_{3,1,t-1} - 0,33N_{3,1,t-2}
\end{aligned} \tag{4.15}$$

$$\begin{aligned}
Z_{4,1,t}^{(1)} = & 36,25t + 5006,4S_1 + 4384S_2 + 6176,6S_3 + 6296,5S_4 + 7155,6S_5 + 6192,5S_6 + \\
& 5386,3S_7 + 5131,6S_8 + 5903,6S_9 + 5543,4S_{10} + 5457S_{11} + 5097S_{12} + \\
& 2412,1V_{2,t-1} - 1432V_{3,t} - 7230I_t^{(165)} + N_{4,1,t} - 0,5N_{4,1,t-1} - 0,19N_{4,1,t-2} - \\
& 0,21N_{4,1,t-3}.
\end{aligned} \tag{4.16}$$

Setelah diperoleh persamaan model ARIMAX untuk masing-masing data penumpang dan kargo di Bandara Soekarno Hatta, maka dilakukan evaluasi kebaikan model. Kriteria evaluasi model yang digunakan adalah dengan kriteria RMSE dan MAPE baik untuk data *training* dan *testing* yang ditampilkan pada Tabel 4.12.

Tabel 4.12. Hasil Peramalan Model ARIMAX di Bandara Soekarno Hatta

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	72.216,12	6,39	99.661,70	4,88
Domestik datang	98.751,74	7,43	126.154,55	5,16
Internasional berangkat	21.549,48	5,15	37.565,72	5,13
Internasional datang	24.988,34	6,53	68.391,11	9,14
Kargo:				
Domestik dimuat	948,91	6,42	22.63,74	10,66
Domestik dibongkar	524,64	6,90	1.480,62	29,76
Internasional dimuat	1.335,97	11,05	1.858,41	12,01
Internasional dibongkar	1.664,17	14,38	2.813,70	19,68

4.2.3 Hasil Pengujian Nonlinieritas

Pemodelan hibrida dilakukan untuk memperkecil nilai residual dari model regresi *time series* atau model ARIMAX. Metode hibrida bekerja dengan

meramalkan residual berdasarkan residual masa lalunya. Pemodelan residual lebih kompleks karena mengandung komponen nonlinier, sehingga pengujian nonlinieritas perlu dilakukan. Pengujian nonlinieritas yang digunakan adalah uji terasvirta. Pengujian ini menggunakan input yang sama pada regresi *time series* kecuali variabel *dummy*. Hal tersebut untuk memastikan apakah persamaan regresi tersebut memiliki hubungan nonlinier yang terabaikan (*neglected nonlinierity*), sehingga komponen nonlinier tersebut akan ditangkap pada pemodelan residualnya menggunakan pendekatan *machine learning*.

Hasil uji terasvirta pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta menyatakan bahwa persamaan regresi *time series* antara $Y_{1,1,t}$ dengan input $t, Y_{1,1,t-1}, Y_{1,1,t-5}, Y_{1,1,t-12}$, dan $Y_{1,1,t-13}$ mengandung komponen nonlinier yang terabaikan (*neglected nonlinierity*). Hubungan yang nonlinier terlihat dari *p-value* kurang dari taraf uji $\alpha = 0,05$. Hasil pengujian terasvirta pada keseluruhan data Bandara Soekarno Hatta dijabarkan Tabel 4.13.

Tabel 4.13. Hasil Pengujian Nonlinieritas di Bandara Soekarno Hatta

Data	Chi-Square	df	<i>p-value</i>	Input
Penumpang:				
Domestik berangkat	104,8	50	0,00001	$t, Y_{1,1,t-1}, Y_{1,1,t-5}, Y_{1,1,t-12}, Y_{1,1,t-13}$
Domestik datang	45,947	30	0,03144	$t, Y_{2,1,t-1}, Y_{2,1,t-2}, Y_{2,1,t-12}$
Internasional berangkat	48,148	30	0,01916	$t, Y_{3,1,t-1}, Y_{3,1,t-3}, Y_{3,1,t-12}$
Internasional datang	74,049	50	0,01518	$t, Y_{4,1,t-1}, Y_{4,1,t-3}, Y_{4,1,t-9}, Y_{4,1,t-12}$
Kargo:				
Domestik dimuat	32,592	16	0,00837	$t, Z_{1,1,t-1}, Z_{1,1,t-3}$
Domestik dibongkar	29,077	16	0,02342	$Z_{2,1,t-1}, Z_{2,1,t-2}, Z_{2,1,t-8}$
Internasional dimuat	50,735	16	0,00002	$t, Z_{3,1,t-1}, Z_{3,1,t-13}$
Internasional dibongkar	18,524	7	0,00982	$t, Z_{4,1,t-1}$

Tabel 4.13 menunjukkan bahwa hubungan nonlinier yang terabaikan (*neglected non linierity*) terlihat pada keseluruhan data penumpang dan kargo di Bandara Soekarno Hatta. Hal ini berarti bahwa tahap selanjutnya layak dilakukan pemodelan menggunakan metode hibrida.

4.2.4 Pemodelan Hibrida TSR-NN

Pada pemodelan hibrida TSR-NN, model pertama menggunakan metode regresi *time series* dengan memasukkan tren, musiman dan efek variasi kalender ke


dalam komponen linier. Residual dari model regresi *time series* ini dianggap masih mengandung komponen nonlinier, sehingga residual ini dimodelkan dengan menggunakan metode FFNN. Model regresi *time series* yang diperoleh sudah dijelaskan sebelumnya pada sub bab 4.2.1. Residual dari model regresi *time series* ini dimodelkan dengan FFNN dengan tiga layer. Layer pertama merupakan *layer input*. Layer kedua adalah *hidden layer* yang terdiri antara 1 sampai 10 *neuron*, yang nantinya dipilih jumlah *neuron* mana yang menghasilkan MAPEP minimum. Sedangkan *layer* terakhir adalah *layer output*.

Dalam pemodelan residual TSR untuk data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta, input yang digunakan mengikuti *lag* yang signifikan pada pemodelan TSR. Hal tersebut bertujuan untuk menangkap komponen non linier yang terabaikan dari pemodelan TSR melalui pemodelan lanjutan menggunakan nilai residualnya. Oleh karena itu, input yang digunakan dalam model FFNN untuk residual TSR pada data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta adalah $N_{1,1,t-1}$, $N_{1,1,t-5}$, $N_{1,1,t-12}$, dan $N_{1,1,t-13}$. Pemilihan jumlah *neuron* pada *hidden layer* dengan cara memilih jumlah *neuron* yang menghasilkan kriteria kebaikan model MAPEP minimum. Uji coba menggunakan hingga 10 *hidden neuron*. Hasil percobaan untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta ditampilkan pada Tabel 4.14.

Tabel 4.14 Pemilihan *hidden neuron* model TSR-NN data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta

Data	MAPE	MAPEP
TSR	4,31	6,80
TSR-NN (4,1,1)	3,79	6,83
TSR-NN (4,2,1)	3,69	6,95
TSR-NN (4,3,1)	3,45	7,34
TSR-NN (4,4,1)	3,53	7,34
TSR-NN (4,5,1)	3,40	7,81
TSR-NN (4,6,1)	3,13	7,98
TSR-NN (4,7,1)	3,11	6,63
TSR-NN (4,8,1)	2,76	7,85
TSR-NN (4,9,1)	2,65	6,92
TSR-NN (4,10,1)	2,46	5,77

Tabel 4.14 menunjukkan bahwa metode hibrida dapat secara signifikan mengurangi nilai MAPE TSR pada data *in-sample* sebesar 42,87 persen dari 4,31 menjadi 2,46. Semakin banyak *neuron* yang digunakan akan menghasilkan nilai ramalan yang baik pada *in-sample*. Namun pada *out-sample*, semakin banyak *hidden neuron* tidak selalu menghasilkan akurasi peramalan yang lebih baik. Pemilihan *hidden neuron* yang tepat sangatlah penting karena tidak semua pemodelan NN dapat mengurangi residual dari TSR terutama pada *out-sample*. Sehingga arsitektur terbaik untuk data residual TSR jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta adalah NN (4,10,1). Dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi aktivasi linier pada *layer output*. Arsitektur NN terbaik untuk residual TSR data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta ditunjukkan pada Gambar 4.8.



Gambar 4.8 Arsitektur Pemodelan NN untuk residual TSR data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta dengan 10 *hidden neuron*.

Model NN residual TSR jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta secara matematis dapat dituliskan sebagai berikut:

$$\begin{aligned} \hat{N}_{1,1,t}^{(2)} = & -1,04 - 1,25f_1^h + 6,09f_2^h - 2,14f_3^h + 1,29f_4^h + 3,18f_5^h - 1,24f_6^h - 1,35f_7^h - \\ & 6,66f_8^h + 1,03f_9^h + 2,89f_{10}^h \end{aligned} \quad (4.17)$$

dengan:

$$\begin{aligned} f_1^h(.) &= (1 + \exp(-(-3,06 + 43,96N_{1,1,t-1} - 72,54N_{1,1,t-5} - 119,32N_{1,1,t-12} + 98,89N_{1,1,t-13})))^{-1} \\ f_2^h(.) &= (1 + \exp(-(4,07 + 0,89N_{1,1,t-1} - 3,37N_{1,1,t-5} - 3,27N_{1,1,t-12} + 12,82N_{1,1,t-13})))^{-1} \\ f_3^h(.) &= (1 + \exp(-(-0,50 + 1,68N_{1,1,t-1} + 0,78N_{1,1,t-5} - 0,18N_{1,1,t-12} + 0,32N_{1,1,t-13})))^{-1} \\ f_4^h(.) &= (1 + \exp(-(-70,34 - 82,73N_{1,1,t-1} + 6,77N_{1,1,t-5} + 30,9N_{1,1,t-12} + 99,65N_{1,1,t-13})))^{-1} \\ f_5^h(.) &= (1 + \exp(-(7,57 - 2,98N_{1,1,t-1} + 5,14N_{1,1,t-5} - 3,35N_{1,1,t-12} + 6,71N_{1,1,t-13})))^{-1} \\ f_6^h(.) &= (1 + \exp(-(-22,97 - 71,72N_{1,1,t-1} + 35,4N_{1,1,t-5} + 75,59N_{1,1,t-12} - 54,76N_{1,1,t-13})))^{-1} \\ f_7^h(.) &= (1 + \exp(-(43,84 + 34,16N_{1,1,t-1} - 140,28N_{1,1,t-5} - 54,79N_{1,1,t-12} + 13,05N_{1,1,t-13})))^{-1} \\ f_8^h(.) &= (1 + \exp(-(3,24 + 0,53N_{1,1,t-1} - 2,15N_{1,1,t-5} - 2N_{1,1,t-12} + 9,51N_{1,1,t-13})))^{-1} \\ f_9^h(.) &= (1 + \exp(-(128,26 - 14,52N_{1,1,t-1} - 93,72N_{1,1,t-5} - 96,59N_{1,1,t-12} - 87,2N_{1,1,t-13})))^{-1} \\ f_{10}^h(.) &= (1 + \exp(-(-7,5 + 2,68N_{1,1,t-1} - 5,88N_{1,1,t-5} - 1,04N_{1,1,t-12} - 1,25N_{1,1,t-13})))^{-1}. \end{aligned}$$

Melalui tahapan yang sama, maka akan dihasilkan model TSR-NN untuk keseluruhan data penumpang dan kargo. Tahapan pemilihan model serta arsitektur model terbaiknya masing-masing data penumpang dan kargo secara rinci disajikan dalam lampiran 10A. Adapun hasil peramalan TSR-NN berdasarkan kriteria akurasi peramalan RMSE dan MAPE baik pada data *training* maupun data *testing* untuk keseluruhan data penumpang dan kargo di Bandara Soekarno Hatta dapat dilihat pada Tabel 4.15.

Tabel 4.15 Hasil Peramalan Model Hibrida TSR-NN di Bandara Soekarno Hatta

Data	Model TSR-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(4,10,1)	35.802,92	2,46	121.591,62	5,77
Domestik datang	(3,9,1)	62.835,58	3,61	149.370,97	5,51
Internasional berangkat	(3,4,1)	23.472,49	5,42	42.212,95	4,41
Internasional datang	(4,1,1)	26.201,19	6,17	56.065,18	6,86
Kargo:					
Domestik dimuat	(2,7,1)	874,83	5,79	2.190,29	10,52
Domestik dibongkar	(3,2,1)	562,96	6,95	1.444,68	28,41
Internasional dimuat	(2,6,1)	1.186,84	9,55	1.678,18	10,49
Internasional dibongkar	(1,9,1)	1.288,23	11,46	2.447,83	16,00

Setelah diperoleh nilai akurasi peramalan pada seluruh data penumpang dan kargo di Bandara Soekarno Hatta maka secara rata-rata pada data *in-sample* model hibrida TSR-NN mampu mengurangi Nilai MAPE model TSR sebesar 47,22 persen pada data penumpang dan sebesar 17,55 persen pada data kargo. Sedangkan untuk

data *out-sample* penumpang dan kargo di Bandara Soekarno Hatta, model hibrida TSR-NN hanya mampu mengurangi Nilai MAPEP model TSR sebesar 11,33 persen untuk data penumpang dan sebesar 2,89 persen untuk data kargo. Adapun representasi matematis dari model hibrida TSR-NN untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta sebagai berikut:

$$\hat{Y}_{1,1,t} = \hat{Y}_{1,1,t}^{(1)} + \hat{N}_{1,1,t}^{(2)}$$

dengan $\hat{Y}_{1,1,t}^{(1)}$ seperti pada persamaan (4.1) dan $\hat{N}_{1,1,t}^{(2)}$ seperti pada persamaan (4.17).

4.2.5 Pemodelan Hibrida ARIMAX-NN


Model pertama yang digunakan pada pemodelan hibrida ARIMAX-NN, adalah metode ARIMAX dengan model variasi kalender ke dalam komponen linier yang telah dijelaskan sebelumnya pada sub bab 4.2.2. Residual dari ARIMAX ini dianggap masih mengandung komponen nonlinier, sehingga residual ini dimodelkan dengan menggunakan metode FFNN. Pemodelan FFNN pada residual model ARIMAX menggunakan arsitektur dengan FFNN dengan tiga layer. Layer pertama merupakan layer input. Layer kedua merupakan *hidden layer* yang terdiri antara 1 sampai 10 *neuron*, yang nantinya dipilih jumlah *neuron* mana yang menghasilkan MAPEP minimum. Sedangkan layer terakhir adalah *layer output*.

Pada pemodelan residual model ARIMAX untuk data jumlah penumpang yang berangkat dari Bandara Soekarno Hatta, input yang digunakan pada residual ARIMAX mengikuti lag data yang signifikan di PACF dari pemodelan ARIMAX itu sendiri. Hal tersebut bertujuan untuk menangkap komponen non linier yang terabaikan dari pemodelan ARIMAX. Sehingga input yang digunakan untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta adalah $N_{1,1,t-1}$, $N_{1,1,t-2}$, $N_{1,1,t-5}$, dan $N_{1,1,t-12}$. Pemilihan jumlah *neuron* pada *hidden layer* dengan cara memilih jumlah *neuron* yang menghasilkan kriteria kebaikan model MAPEP minimum. Uji coba menggunakan hingga 10 *hidden neuron*. Hasil percobaan untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta ditampilkan pada Tabel 4.16.

Tabel 4.16. Pemilihan *hidden neuron* model ARIMAX-NN data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta

Data	MAPE	MAPEP
ARIMAX	6,52	5,02
ARIMAX-NN (4,1,1)	5,12	5,11
ARIMAX-NN (4,2,1)	5,10	5,24
ARIMAX-NN (4,3,1)	4,73	5,52
ARIMAX-NN (4,4,1)	5,00	5,49
ARIMAX-NN (4,4,1)	4,55	5,42
ARIMAX-NN (4,6,1)	4,55	6,16
ARIMAX-NN (4,7,1)	4,35	5,73
ARIMAX-NN (4,8,1)	4,06	4,39
ARIMAX-NN (4,9,1)	3,56	4,11
ARIMAX-NN (4,10,1)	3,56	7,54

Tabel 4.16 menjelaskan bahwa metode hibrida dapat mereduksi MAPE model ARIMAX data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta pada data *in-sample* sebesar 45,42 persen dari 6,39 menjadi 3,56. Semakin banyak *neuron* yang digunakan akan menghasilkan nilai ramalan terbaik pada *in-sample*. Namun pada *out-sample*, semakin banyak *hidden neuron* tidak selalu menghasilkan akurasi peramalan yang lebih baik. Pemilihan *hidden neuron* yang tepat sangatlah penting karena tidak semua pemodelan NN dapat mengurangi residual dari ARIMAX terutama pada *out-sample*. Sehingga arsitektur NN terbaik data residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta adalah FFNN (4,9,1) yang ditunjukkan Gambar 4.9. Dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi aktivasi linier pada *layer output*.



Gambar 4.9 Arsitektur Pemodelan NN untuk residual model ARIMAX data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta dengan 9 *hidden neuron*

Model NN residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta secara matematis dapat dituliskan sebagai berikut:

$$\begin{aligned} \hat{N}_{1,1,t}^{(2)} = & -1,64 + 0,97f_1^h + 2,94f_2^h + 0,99f_3^h - 0,78f_4^h + 1,77f_5^h - 2,27f_6^h + 1,23f_7^h - \\ & 1,44f_8^h - 3,10f_9^h \end{aligned} \quad (4.18)$$

dengan:

$$\begin{aligned} f_1^h(.) &= (1 + \exp(-(-39,09 + 30,624N_{1,1,t-1} - 0,67N_{1,1,t-2} - 183,18N_{1,1,t-5} + 122N_{1,1,t-12})))^{-1} \\ f_2^h(.) &= (1 + \exp(-(2,28 - 0,34N_{1,1,t-1} + 2,61N_{1,1,t-2} - 2,16N_{1,1,t-5} + 6,22N_{1,1,t-12})))^{-1} \\ f_3^h(.) &= (1 + \exp(-(36,96 - 49,2N_{1,1,t-1} - 7,29N_{1,1,t-2} + 46N_{1,1,t-5} - 119,03N_{1,1,t-12})))^{-1} \\ f_4^h(.) &= (1 + \exp(-(-60,09 - 75,75N_{1,1,t-1} - 78,53N_{1,1,t-2} - 17,72N_{1,1,t-5} + 5,28N_{1,1,t-12})))^{-1} \\ f_5^h(.) &= (1 + \exp(-(-1,89 - 40,9N_{1,1,t-1} + 9N_{1,1,t-2} - 81,09N_{1,1,t-5} - 59,01N_{1,1,t-12})))^{-1} \\ f_6^h(.) &= (1 + \exp(-(-13,1 + 4,76N_{1,1,t-1} + 4,7N_{1,1,t-2} - 1,47N_{1,1,t-5} + 3,99N_{1,1,t-12})))^{-1} \\ f_7^h(.) &= (1 + \exp(-(41,31 + 44,87N_{1,1,t-1} + 50,84N_{1,1,t-2} + 92,25N_{1,1,t-5} + 85,88N_{1,1,t-12})))^{-1} \\ f_8^h(.) &= (1 + \exp(-(-1,98 - 9,77N_{1,1,t-1} + 5,76N_{1,1,t-2} - 70N_{1,1,t-5} - 21,96N_{1,1,t-12})))^{-1} \\ f_9^h(.) &= (1 + \exp(-(0,73 - 0,18N_{1,1,t-1} + 2,11N_{1,1,t-2} - 0,71N_{1,1,t-5} + 3,14N_{1,1,t-12})))^{-1}. \end{aligned}$$

Adapun hasil pemodelan hibrida ARIMAX-NN ketujuh data lainnya baik dalam pemilihan *hidden neuron* serta arsitektur NN terbaik secara rinci ditampilkan dalam lampiran 10A. Ringkasan dari pemodelan hibrida ARIMAX-NN untuk keseluruhan data penumpang dan kargo di Bandara Soekarno Hatta dapat dilihat pada Tabel 4.17.

Tabel 4.17 Hasil Peramalan Model hibrida ARIMAX-NN di Bandara Soekarno Hatta

Data	Model ARIMAX-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(4,9,1)	47.607,45	3,56	95.127,78	4,11
Domestik datang	(2,5,1)	82.595,82	5,26	116.450,43	4,97
Internasional berangkat	(2,7,1)	19.694,49	4,52	38.385,14	4,86
Internasional datang	(5,4,1)	19.762,39	4,93	55.470,50	7,31
Kargo:					
Domestik dimuat	(2,2,1)	881,65	5,77	2.250,15	10,44
Domestik dibongkar	(2,9,1)	372,33	4,87	1.304,26	24,13
Internasional dimuat	(2,5,1)	1.216,53	9,48	1.811,08	11,33
Internasional dibongkar	(3,1,1)	1.663,80	14,21	2.788,95	19,60

Setelah diperoleh nilai akurasi peramalan pada seluruh data penumpang dan kargo di Bandara Soekarno Hatta maka secara rata-rata pada data *in-sample* model hibrida ARIMAX-NN mampu mengurangi MAPE model ARIMAX sebesar 38,37 persen pada data penumpang dan sebesar 25,44 persen pada data kargo. Sedangkan secara rata-rata untuk data *out-sample* penumpang dan kargo di Bandara Soekarno Hatta, model hibrida ARIMAX-NN hanya mampu mengurangi MAPE model

ARIMAX sebesar 11,18 persen pada data penumpang dan sebesar 6,75 persen pada data kargo. Secara Matematis model hibrida ARIMAX-NN pada data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta dapat dituliskan sebagai berikut:

$$Y_{1,1,t} = Y_{1,1,t}^{(1)} + N_{1,1,t}^{(2)} + e_{1,1,t}$$

dengan $Y_{1,1,t}^{(1)}$ seperti pada persamaan (4.9) dan $N_{1,1,t}^{(2)}$ seperti pada persamaan (4.18).

4.2.6 Pemodelan Hibrida TSR-SVR

Pemodelan TSR-SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan. hal ini bertujuan untuk mendapatkan hasil yang global optimum. Input yang digunakan dalam model TSR-SVR sama dengan input yang digunakan dalam model TSR-NN. Parameter yang dimiliki model SVR ada tiga yaitu parameter *epsilon*, σ^2 , dan C. Untuk mendapatkan parameter yang optimum perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai MAPEP yang terkecil.

Kombinasi Nilai σ^2 yang digunakan antara 0,01 sampai dengan 1 (Shabri, 2015). Nilai parameter *epsilon* yang digunakan dari rentang nilai antara 10 sampai dengan 100. Sedangkan untuk nilai C yang digunakan dari rentang 1000 hingga 100000. Kombinasi antara ketiga parameter tersebut menghasilkan puluhan ribu kombinasi hasil pencarian yang kemudian dipilih dengan nilai MAPE terkecil. Berikut ditampilkan hasil 10 kombinasi parameter pemodelan SVR data residual TSR jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta seperti pada Tabel 4.18.

Tabel 4.18 Hasil Pencarian MAPE terkecil model SVR data residual TSR jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta

Epsilon	C	σ^2	MAPE	MAPEP
750	1000	0,05	3,895	5,260
800	1000	0,05	3,895	5,260
850	1000	0,05	3,895	5,260
1000	3000	0,05	3,722	5,265
1000	3000	0,06	3,722	5,265
1000	3000	0,07	3,722	5,265
450	3000	0,05	3,718	5,266
450	3000	0,06	3,718	5,266
450	3000	0,07	3,718	5,266
1000	5000	0,05	3,554	5,270

Tabel 4.18 memperlihatkan hasil pemodelan untuk data residual TSR jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta menggunakan ketiga parameter tersebut menghasilkan nilai MAPE pada data *out sample* yang paling kecil adalah sebesar 5,26 dengan menggunakan parameter nilai *epsilon* 750, nilai C sebesar 1000, dan nilai σ^2 sebesar 0,05. Berikut hasil model optimum SVR untuk data residual TSR penumpang domestik yang berangkat dari Bandara Soekarno Hatta:

$$\begin{aligned}\hat{N}_{1,1,t}^{(2)} &= \sum_{i=29}^{200} (\hat{\alpha}_i - \hat{\alpha}_i^*) \exp\left(-\frac{\|N_i - N_i^*\|^2}{2\sigma^2}\right) + b \\ &= -1000 \exp\left(-\frac{\|N_{29} - N_i^*\|^2}{0,1}\right) + 1000 \exp\left(-\frac{\|N_{30} - N_i^*\|^2}{0,1}\right) - 1000 \exp\left(-\frac{\|N_{31} - N_i^*\|^2}{0,1}\right) + \dots + \\ &\quad 1000 \exp\left(-\frac{\|N_{198} - N_i^*\|^2}{0,1}\right) + 1000 \exp\left(-\frac{\|N_{199} - N_i^*\|^2}{0,1}\right) - 1000 \exp\left(-\frac{\|N_{200} - N_i^*\|^2}{0,1}\right) + \\ &\quad 2372,235\end{aligned}\quad (4.19)$$

dengan $N_i = [N_{1,1,t-1} \ N_{1,1,t-5} \ N_{1,1,t-12} \ N_{1,1,t-13}]$

$$N_i^* = [N_{1,1,t-2} \ N_{1,1,t-6} \ N_{1,1,t-13} \ N_{1,1,t-14}].$$

Model optimum SVR ini memiliki *support vector* sebanyak 172, artinya ada 172 taksiran parameter ($\hat{\alpha}_i - \hat{\alpha}_i^*$) tidak bernilai nol. Selanjutnya dengan cara yang sama akan diperoleh model hibrida TSR-SVR untuk ketujuh data lainnya. Hasil model TSR-SVR terbaik untuk data penumpang dan kargo Bandara Soekarno Hatta dijabarkan pada Tabel 4.19. Sedangkan hasil pencarian model terbaiknya masing-masing dapat dilihat secara rinci dalam lampiran 11A. Selain itu juga ditampilkan hasil ramalan data *training* dan data *testing* menggunakan nilai RMSE dan MAPE.

Tabel 4.19 Hasil Peramalan Model hibrida TSR-SVR di Bandara Soekarno Hatta

Data	Parameter			Akurasi Peramalan			
	<i>Epsilon</i>	C	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	750	1.000	0,05	57.536,55	3,89	112.948,57	5,26
Domestik datang	100	1.000	0,1	88.379,26	5,18	167.347,66	6,41
Internasional berangkat	100	25.000	0,07	11.616,12	1,64	42.028,42	5,19
Internasional datang	100	1.000	0,1	26.962,71	6,19	52.776,47	6,86
Kargo:							
Domestik dimuat	100	1.000	0,1	450,12	2,06	2.636,54	12,86
Domestik dibongkar	10	1.000	0,05	149,65	0,67	807,57	14,41
Internasional dimuat	1.000	1.000	0,05	926,83	8,12	2.682,55	17,67
Internasional dibongkar	96	1.000	0,06	906,37	5,31	2.819,87	18,44

Dari Tabel 4.19 terlihat bahwa metode *grid search* mampu menghasilkan model yang paling optimum. Selain itu metode hibrida TSR-SVR secara rata-rata dapat mengurangi residual TSR pada data *in-sample* hingga 32,69 persen untuk data penumpang dan 60,05 persen untuk data kargo di Bandara Soekarno Hatta. Namun pada *out-sample*, hasil ramalan hibrida TSR-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik dibandingkan dengan model TSR. Berikut model hibrida TSR-SVR untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta:

$$\hat{Y}_{1,1,t} = \hat{Y}_{1,1,t}^{(1)} + \hat{N}_{1,1,t}^{(2)}$$

dengan $\hat{Y}_{1,1,t}^{(1)}$ seperti pada persamaan (4.1) dan $\hat{N}_{1,1,t}^{(2)}$ seperti pada persamaan (4.19).

4.2.7 Pemodelan Hibrida ARIMAX-SVR

Pemodelan ARIMAX-SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan untuk mendapatkan hasil yang global optimum. Input yang digunakan dalam model ARIMAX-SVR sama dengan input yang digunakan dalam model ARIMAX-NN. Parameter yang dimiliki model SVR ada tiga yaitu parameter *epsilon*, σ^2 , dan *C*, untuk mendapatkan parameter yang optimum perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai MAPE yang terbaik pada data *in-sample* dan data *out-sample*. Kombinasi nilai parameter *epsilon* yang digunakan dari rentang nilai antara 10 sampai dengan 100. Sedangkan untuk nilai σ^2 yang digunakan antara 0,01 sampai dengan 0,1. Nilai *C* yang digunakan dari rentang 1000 hingga 100000. Kombinasi antara ketiga parameter tersebut menghasilkan ribuan hasil pencarian yang kemudian dipilih dengan nilai MAPE terkecil.

Tabel 4.20 menunjukkan hasil 10 kombinasi parameter pemodelan SVR data residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta. Berdasarkan pada hasil metode *grid search* tersebut, maka untuk data residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta menggunakan ketiga parameter tersebut menghasilkan nilai MAPE pada data *out-sample* yang paling kecil adalah sebesar 5,1855 dengan

menggunakan parameter nilai epsilon 1000, nilai C sebesar 1000, dan nilai σ^2 sebesar 0,05.

Tabel 4.20 Hasil Pencarian MAPE terkecil model SVR data residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta

Epsilon	C	σ^2	MAPE	MAPEP
1000	1000	0,05	5,1069	5,1855
1000	1000	0,06	5,1069	5,1855
1000	1000	0,07	5,1069	5,1855
900	1000	0,05	5,1066	5,1859
900	1000	0,06	5,1066	5,1859
900	1000	0,07	5,1066	5,1859
700	1000	0,05	5,1061	5,1860
700	1000	0,06	5,1061	5,1860
700	1000	0,07	5,1061	5,1860
100	3000	0,05	4,8984	5,1950

Hasil model optimum SVR untuk data residual ARIMAX jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta yaitu:

$$\begin{aligned}
\hat{N}_{1,1,t}^{(2)} &= \sum_{i=16}^{200} (\hat{\alpha}_i - \hat{\alpha}_i^*) \exp\left(-\frac{\|N_i - N_{i^*}\|^2}{2\sigma^2}\right) + b \\
&= -1000 \exp\left(-\frac{\|N_{16} - N_{i^*}\|^2}{0,1}\right) + 1000 \exp\left(-\frac{\|N_{17} - N_{i^*}\|^2}{0,1}\right) + 1000 \exp\left(-\frac{\|N_{18} - N_{i^*}\|^2}{0,1}\right) + \dots + \\
&\quad 1000 \exp\left(-\frac{\|N_{198} - N_{i^*}\|^2}{0,1}\right) + 1000 \exp\left(-\frac{\|N_{199} - N_{i^*}\|^2}{0,1}\right) - 1000 \exp\left(-\frac{\|N_{200} - N_{i^*}\|^2}{0,1}\right) - \\
&\quad 4589,288
\end{aligned} \tag{4.20}$$

dengan $N_i = [N_{1,1,t-1} \ N_{1,1,t-2} \ N_{1,1,t-5} \ N_{1,1,t-12}]$

$N_{i^*} = [N_{1,1,t-2} \ N_{1,1,t-3} \ N_{1,1,t-6} \ N_{1,1,t-13}]$.

Model optimum SVR ini memiliki *support vector* sebanyak 185, artinya ada 185 taksiran parameter $(\hat{\alpha}_i - \hat{\alpha}_i^*)$ tidak bernilai nol. Selanjutnya pada Tabel 4.21 ditampilkan hasil parameter terbaiknya model ARIMAX-SVR untuk keseluruhan data penumpang dan kargo Bandara Soekarno Hatta. Sedangkan hasil kombinasi parameter dengan menggunakan metode *grid search* beserta model terbaiknya masing-masing dapat dilihat secara rinci dalam Lampiran 11A. Selain itu juga pada Tabel 4.21 ditampilkan hasil ramalan masing-masing data penumpang dan kargo dengan menggunakan nilai RMSE dan MAPE.

Tabel 4.21 Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara Soekarno Hatta

Data	Parameter			Akurasi			
	<i>Epsilon</i>	C	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	1.000	1.000	0,05	71.473,81	5,11	107.776,20	5,19
Domestik datang	100	1.000	0,1	98.687,32	6,17	142.412,25	5,47
Internasional berangkat	1.000	11.000	0,05	15.062,31	2,60	32.053,34	4,43
Internasional datang	100	43.000	0,1	4.990,88	0,43	50.185,03	6,70
Kargo:							
Domestik dimuat	1.000	1.000	0,05	712,84	5,26	2.590,91	11,81
Domestik dibongkar	100	1.000	0,05	148,67	2,00	798,87	13,96
Internasional dimuat	1.000	5.000	0,1	772,61	7,59	2.395,12	15,74
Internasional dibongkar	1.000	1.000	0,05	1.228,61	10,82	3.175,04	20,02

Tabel 4.21 menjelaskan bahwa metode hibrida dapat mereduksi nilai MAPE dari model ARIMAX pada data *in-sample* dengan rata-rata sebesar 45,01 persen pada data penumpang dan 36,32 persen pada data kargo di Bandara Soekarno Hatta. Pemilihan parameter yang tepat akan membuat nilai ramalan yang baik pada *in-sample*. Namun pada *out-sample*, hasil ramalan hibrida ARIMAX-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik. Berikut ini merupakan model hibrida ARIMAX-SVR untuk data jumlah penumpang domestik yang berangkat dari Bandara Soekarno Hatta.

$$Y_{1,1,t} = Y_{1,1,t}^{(1)} + N_{1,1,t}^{(2)} + e_{1,1,t}$$

dengan $Y_{1,1,t}^{(1)}$ seperti pada persamaan (4.9) dan $N_{1,1,t}^{(2)}$ seperti pada persamaan (4.20).


4.2.8 Perbandingan Hasil Model Peramalan

Perbandingan hasil pemodelan TSR, ARIMAX dengan variasi kalender, hibrida TSR-NN, hibrida TSR-SVR, hibrida ARIMAX-NN dan hibrida ARIMAX-SVR dilakukan untuk melihat tingkat akurasi peramalan. Tabel 4.22 menampilkan hasil ramalan pada data *testing* yang dihitung dengan kriteria RMSEP dan MAPEP. Pemilihan model peramalan terbaik dari keenam model tersebut berdasarkan pada nilai MAPEP terkecil. Hal tersebut disebabkan karena nilai MAPE lebih mudah dalam menggambarkan rata-rata *error* dari keseluruhan data. Sedangkan RMSE sensitif terhadap *outlier*. Karena dihitung nilai kuadratnya, *error outlier* akan memberikan bobot yang besar dan membuat nilai RMSE semakin besar.

Tabel 4.22 Hasil Akurasi Peramalan Data *Out-Sample* Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara Soekarno Hatta


Data	Metode Peramalan					
	TSR	ARIMAX	TSR-NN	TSR-SVR	ARIMAX-NN	ARIMAX-SVR
Nilai RMSEP						
Penumpang Domestik						
Berangkat	135.754,47	99.661,70	121.591,62	112.948,57	95.127,78	107.776,20
Datang	166.945,57	126.154,55	149.370,97	167.347,66	116.450,43	142.412,25
Penumpang Internasional						
Berangkat	41.627,03	37.565,72	42.212,95	42.028,42	38.385,14	32.053,34
Datang	58.849,01	68.391,11	56.065,18	52.776,47	55.470,50	50.185,03
Kargo Domestik						
Berangkat	2.394,36	2.263,74	2.190,29	2.636,54	2.250,15	2.590,91
Datang	1.432,65	1.480,62	1.444,68	807,57	1.304,26	798,87
Kargo Internasional						
Berangkat	1.720,78	1.858,41	1.678,18	2.682,55	1.811,08	2.395,12
Datang	2.408,68	2.813,70	2.447,83	2.819,87	2.788,95	3.175,04
Nilai MAPEP						
Penumpang Domestik						
Berangkat	6,80	4,88	5,77	5,26	4,11	5,19
Datang	6,39	5,16	5,51	6,41	4,97	5,47
Penumpang Internasional						
Berangkat	4,99	5,13	4,41	5,19	4,86	4,43
Datang	7,22	9,14	6,86	6,86	7,31	6,70
Kargo Domestik						
Berangkat	11,54	10,66	10,52	12,86	10,44	11,81
Datang	28,77	29,76	28,41	14,41	24,13	13,96
Kargo Internasional						
Berangkat	10,51	12,01	10,49	17,67	11,33	15,74
Datang	16,20	19,68	16,00	18,44	19,60	20,02

Selanjutnya perbandingan data hasil ramalan semua metode pada data *out-sample* untuk periode September 2016 hingga Agustus 2017 dapat divisualisasikan kedalam Gambar 4.10.



Gambar 4.10. Hasil ramalan *out-sample* pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Soekarno Hatta.

Adapun secara visual, perbandingan nilai MAPEP per bulan ramalan (MAPEP *Adaptive*) dari masing-masing metode dapat dilihat pada Gambar 4.11.



Gambar 4.11. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara Soekarno Hatta.

Tabel 4.22 dan Gambar 4.11 menunjukkan bahwa metode terbaik untuk meramalkan data penumpang dan kargo di Bandara Soekarno Hatta dapat berbeda-beda. Sehingga untuk pemodelan data jumlah penumpang domestik yang berangkat, data jumlah penumpang domestik yang datang, dan kargo domestik yang

dimuat dari Bandara Soekarno Hatta, yang memberikan akurasi terbaik adalah model hibrida ARIMAX-NN. Sedangkan model terbaik untuk data jumlah penumpang internasional yang datang dan data kargo domestik yang dibongkar adalah model hibrida ARIMAX-SVR. Adapun untuk data jumlah penumpang internasional yang berangkat, data kargo internasional yang dimuat dan data kargo internasional yang dibongkar, model terbaiknya hibrida TSR-NN.


4.2.9 Hasil Ramalan Hingga Tahun 2018 di Bandara Soekarno Hatta

Berdasarkan kriteria peramalan pada data *out-sample* tersebut diketahui bahwa hasil ramalan terbaik untuk masing-masing data penumpang dan kargo di Bandara Soekarno Hatta menggunakan model terbaik yang berbeda-beda. Adapun hasil ramalan kedepan periode September 2017 hingga Desember 2018 dengan metode terbaik disajikan pada Tabel 4.23.


Tabel 4.23 Angka Ramalan Penumpang Udara dan Kargo Di Bandara Soekarno Hatta Periode Bulan September 2017 hingga Desember 2018

Periode	Penumpang Domestik		Penumpang Internasional		Kargo Domestik		Kargo Internasional	
	Berangkat	Datang	Berangkat	Datang	Dimuat	Dibongkar	Dimuat	Dibongkar
	ARIMAX-NN	ARIMAX-NN	TSR-NN	ARIMAX-SVR	ARIMAX-NN	ARIMAX-SVR	TSR-NN	TSR-NN
2017								
September	1.757.534	2.359.762	587.187	518.091	20.639	5.860	12.229	12.579
Oktober	1.900.766	2.405.189	546.027	505.619	20.468	5.903	13.704	13.479
November	1.983.747	2.419.338	544.755	530.717	21.637	5.802	13.332	12.375
Desember	2.070.591	2.583.771	667.687	562.012	20.475	6.421	13.990	12.701
2018								
Januari	2.009.426	2.395.707	584.596	574.075	19.056	5.930	12.966	12.110
Februari	1.859.988	2.215.317	553.729	521.968	20.592	5.279	13.032	12.289
Maret	2.031.175	2.427.975	633.798	569.336	20.400	5.719	13.982	13.537
April	1.922.009	2.507.589	613.496	609.312	22.968	5.116	13.738	13.149
Mei	2.132.861	2.340.792	633.940	624.931	19.368	6.206	14.093	14.727
Juni	2.162.259	2.532.523	624.545	644.416	21.359	4.577	13.198	10.621
Juli	2.133.709	2.829.795	607.157	525.834	21.128	7.610	13.712	11.842
Agustus	2.102.833	2.551.028	611.024	610.160	20.983	5.202	13.457	12.027
September	2.005.717	2.513.211	585.814	541.762	21.776	4.350	13.514	14.051
Oktober	2.105.061	2.624.767	593.000	518.499	21.580	5.692	14.034	13.738
November	2.135.397	2.651.599	626.301	504.608	22.722	4.880	15.157	12.653
Desember	2.258.935	2.677.767	665.213	616.325	20.639	6.489	13.545	12.976

Sedangkan secara visual angka prediksi untuk data penumpang ditampilkan pada Gambar 4.12 dan untuk data kargo ditampilkan pada Gambar 4.13. Data *in-sample* yang ditampilkan mulai dari Januari 2013.



Gambar 4.12. Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara Soekarno Hatta.



Gambar 4.13. Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara Soekarno Hatta.

4.3 Pemodelan Bandara Internasional I Gusti Ngurah Rai

Tahapan pemodelan yang dilakukan untuk data penumpang dan kargo di Bandara Internasional I Gusti Ngurah Rai terdiri dari pemodelan tahap pertama dan pemodelan tahap kedua. Pemodelan tahap pertama menggunakan model TSR dan ARIMAX. Sedangkan pemodelan tahap kedua dengan metode peramalan hibrida yaitu TSR-NN, ARIMAX-NN, TSR-SVR, dan ARIMAX-SVR menggunakan input residual model tahap pertama. Dari keempat model tersebut diperoleh model terbaik, kemudian diperoleh angka prediksi 2018 dari model terbaiknya.

4.3.1 Pemodelan *Time Series Regression* (TSR)

Tahapan yang dilakukan dalam pemodelan regresi *time series* ini telah dijelaskan sebelumnya pada sub bab 4.2.1 yaitu dilakukan pemeriksaan diagnosa asumsi residual yang meliputi *white noise* dan distribusi normal, estimasi parameter dan uji signifikansi parameter. Tidak semua data penumpang dan kargo di Bandara I Gusti Ngurah Rai yang bebas dari asumsi residual berdistribusi normal, sehingga perlu dilakukan deteksi *outlier*. Akhirnya akan diperoleh model regresi *time series* yang sudah memenuhi asumsi residual yang *white noise* dan berdistribusi normal, serta dengan parameter yang signifikan. Untuk tahapan pemodelan regresi *time series* pada data penumpang dan kargo di Bandara Internasional I Gusti Ngurah Rai secara rinci disajikan pada lampiran 8B. Adapun hasil pemeriksaan diagnosa data penumpang dan kargo di Bandara I Gusti Ngurah Rai disajikan pada Tabel 4.24.

Tabel 4.24 Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara I Gusti Ngurah Rai

Data	White Noise	Data Outlier Additive ke-	Jenis Outlier	Uji KS (<i>p-value</i>)
Penumpang:				
Domestik berangkat	YA	-	-	0,0919
Domestik datang	YA	125, 150	Additive	0,1368
Internasional berangkat	YA	47, 68, 178, 181	Additive	>0,1500
Internasional datang	YA	179, 180	Additive	>0,1500
Kargo:				
Domestik dimuat	YA	32, 33, 50, 56, 57, 90, 128, 169	Additive	>0,1500
Domestik dibongkar	YA	59, 167, 168	Additive	>0,1500
Internasional dimuat	YA	-	-	>0,1500
Internasional dibongkar	YA	86, 108, 110, 149, 167	Additive	>0,1500

Representasi matematis dari model TSR untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai dapat dituliskan sebagai berikut:

Data Penumpang:

$$\begin{aligned}\hat{Y}_{1,2,t}^{(1)} = & 399,86t + 12620,8S_1 - 16629,1S_2 + 11242S_5 + 25485,5S_7 + 9325,5S_8 + \\ & 7623,4S_{10} - 46303,2V_{1,t-1} - 21702,3V_{2,t-1} + 43386,5V_{1,t} + 26062,8V_{2,t} - \\ & 37475,4,7V_{4,t} + 49431,1V_{4,t+1} + 0,71Y_{1,t-1} + 0,23Y_{1,2,t-11} + 0,26Y_{1,2,t-12} - \\ & 0,39Y_{1,2,t-13}\end{aligned}\quad (4.21)$$

$$\begin{aligned}\hat{Y}_{2,2,t}^{(1)} = & 222,95t - 21696S_1 - 31636,7S_2 + 18210,1S_5 + 18776S_6 + 27397,8S_7 + \\ & 30844,7S_{12} - 49616,2V_{1,t-1} - 32581,3V_{2,t-1} - 24556,9V_{3,t-1} + 19501,4V_{1,t} - \\ & 26043,2V_{4,t} + 0,39Y_{2,2,t-1} + 0,33Y_{2,2,t-2} + 0,20Y_{2,2,t-12} - 51773,1I_t^{(125)} + \\ & 50426,8I_t^{(150)}\end{aligned}\quad (4.22)$$

$$\begin{aligned}\hat{Y}_{3,2,t}^{(1)} = & 1047t - 19158,5S_2 - 21384,1S_3 + 24869,8S_7 + 38204,3S_8 - 40020,6S_{11} - \\ & 31560,7S_{12} + 21904V_{2,t+1} + 0,24Y_{3,2,t-1} + 0,25Y_{3,2,t-2} + 0,03Y_{3,2,t-45} + \\ & 43847,8I_t^{(47)} - 158024,5I_t^{(68)} + 113779,6I_t^{(178)} + 61659,5I_t^{(181)}\end{aligned}\quad (4.23)$$

$$\begin{aligned}\hat{Y}_{4,2,t}^{(1)} = & 249,86t - 10883,2S_1 - 8431,7S_2 + 20999,6S_6 + 28711,3S_7 - 11405,5S_{10} - \\ & 11405,5S_{11} + 21311,2S_{12} - 21800,3V_{1,t-1} - 13054,9V_{1,t+1} + 0,78Y_{4,2,t-1} + \\ & 0,11Y_{4,2,t-12} - 88797,1I_t^{(179)} + 70498,3I_t^{(180)}.\end{aligned}\quad (4.24)$$

Data Kargo:

$$\begin{aligned}\hat{Z}_{1,2,t}^{(1)} = & -0,24t + 106,82S_3 + 115,69S_4 + 132,72S_5 + 100,33S_6 + 115,74S_7 + 64,56S_8 + \\ & 116,39S_9 + 151,1S_{10} + 139,42S_{11} + 90,33S_{12} - 139,37V_{1,t} - 158,07V_{2,t} - \\ & 95,82V_{3,t} - 245,46V_{4,t} + 0,73Z_{1,2,t-1} + 0,23Z_{1,2,t-2} - 0,07Z_{1,2,t-26} + 552,98I_t^{(32)} - \\ & 553,01I_t^{(33)} + 307,87I_t^{(50)} - 218,98I_t^{(56)} - 197,61I_t^{(57)} - 156,21I_t^{(90)} + \\ & 306,23I_t^{(128)} + 468,21I_t^{(169)}\end{aligned}\quad (4.25)$$

$$\begin{aligned}\hat{Z}_{2,2,t}^{(1)} = & 0,79t + 185,07S_3 + 107,42S_4 + 155,49S_5 + 89,9S_6 + 168,14S_7 + 147,68S_8 + \\ & 213,05S_9 + 260,99S_{10} + 142,75S_{11} + 212,88S_{12} - 344,92V_{1,t} - 262,21V_{2,t} - \\ & 239,12V_{3,t} + 183,62V_{2,t+1} + 0,63Z_{2,2,t-1} + 0,18Z_{2,2,t-8} + 1155,5I_t^{(59)} - \\ & 1309,5I_t^{(167)} - 605,26I_t^{(168)}\end{aligned}\quad (4.26)$$

$$\begin{aligned}\hat{Z}_{3,2,t}^{(1)} = & -2,63t + 648,13S_1 + 649,85S_2 + 1273,1S_3 + 1037,3S_4 + 765,47S_5 + 710,24S_6 + \\ & 839,02S_7 + 704,40S_8 + 804,88S_9 + 1177,4S_{10} + 1076,9S_{11} + 1080,3S_{12} - \\ & 505,47V_{1,t-1} - 246,79V_{3,t+1} + 0,54Z_{3,2,t-1} + 0,17Z_{3,2,t-5}\end{aligned}\quad (4.27)$$

$$\begin{aligned}\hat{Z}_{4,2,t}^{(1)} = & 0,61t - 140,27S_1 - 114,15S_2 + 120,54S_3 + 80,34S_{11} + 231,42V_{4,t-1} - 214,36V_{1,t} - \\ & 181,37V_{2,t} - 160,58V_{3,t} - 232,34V_{4,t} + 0,80Z_{4,2,t-1} + 0,14Z_{4,2,t-2} + 493,98I_t^{(86)} + \\ & 1331I_t^{(108)} - 1330,3I_t^{(110)} - 620,82I_t^{(149)} - 741,96I_t^{(167)}.\end{aligned}\quad (4.28)$$

Setelah diperoleh persamaan model TSR untuk masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai, maka kemudian dilakukan evaluasi kebaikan model dengan menggunakan kriteria RMSE dan MAPE untuk data *training* dan *testing* pada Tabel 4.25.

Tabel 4.25. Hasil Peramalan Model TSR di Bandara I Gusti Ngurah Rai

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	16.447,40	6,45	31.346,31	5,79
Domestik datang	16.708,18	6,48	42.750,88	9,22
Internasional berangkat	16.001,99	5,84	75.086,48	12,43
Internasional datang	12.736,97	5,94	42.054,93	6,84
Kargo:				
Domestik dimuat	59,89	10,37	639,72	49,43
Domestik dibongkar	135,51	11,61	189,64	14,75
Internasional dimuat	249,66	9,18	1069,14	38,73
Internasional dibongkar	135,54	15,48	352,56	26,35

4.3.2 Pemodelan ARIMAX

Tahapan pemodelan ARIMAX dengan model variasi kalender secara rinci telah dijabarkan pada sub bab 4.2.2, yaitu data dimodelkan terlebih dahulu dengan model regresi *time series*, dan residual dari hasil pemodelan *time series* tersebut dimodelkan dengan ARIMA berdasarkan pada pola ACF dan PACF. Setelah itu dilanjutkan dengan pengujian asumsi residual *white noise* dan distribusi normal. Tidak semua data penumpang dan kargo udara di Bandara I Gusti Ngurah Rai bebas dari uji asumsi normalitas, sehingga perlu dilakukan deteksi *outlier*. Setelah asumsi *white noise* dan normalitas terpenuhi, maka dilakukan estimasi parameter dan pengujian signifikansi parameter.

Secara rinci seluruh tahapan yang ada pada data penumpang dan kargo di Bandara I Gusti Ngurah Rai dapat dilihat dalam Lampiran 8B dan 9B. Adapun ringkasan pemeriksaan diagnosa untuk keseluruhan data penumpang dan kargo di Bandara I Gusti Ngurah Rai dijelaskan pada Tabel 4.26.

Tabel 4.26 Ringkasan Hasil Pengujian Asumsi Model ARIMAX Bandara I Gusti Ngurah Rai

Data	Model ARIMAX	White Noise	Data Additive Outlier ke-	Uji KS (<i>p-value</i>)
Penumpang:				
Domestik berangkat	(1,0,0)(1,0,0) ¹²	YA	-	0,0953
Domestik datang	(2,0,0)(1,0,0) ¹²	YA	125, 150, 179	0,0771
Internasional berangkat	(1,0,0)(1,0,0) ⁴⁶	YA	178, 183	0,0717
Internasional datang	(2,0,0)(1,0,0) ¹⁰	YA	-	0,0885
Kargo:				
Domestik dimuat	(2,0,0)	YA	32, 168	0,0966
Domestik dibongkar	(2,0,0)	YA	12, 32, 167, 168	0,0838
Internasional dimuat	([1,5],0,0)	YA	-	0,1127
Internasional dibongkar	([1,3],0,0)	YA	17, 86, 108, 109, 159, 167	>0,1500

Secara matematis model regresi ARIMAX pada data penumpang dan kargo di Bandara I Gusti Ngurah Rai dapat dituliskan sebagai berikut:

Data Penumpang:

$$Y_{1,2,t}^{(1)} = 1959,6t + 38667,3S_1 + 24413,9S_5 + 33233,2S_6 + 64170,4S_7 + 55027,2S_8 + 31414,6S_9 + 36466,5S_{10} + 33043,8S_{11} + 38639,1S_{12} - 50751,4V_{1,t-1} - 13856,5V_{3,t} - 52507V_{4,t} + 21518,4V_{4,t+1} + \frac{1}{(1+0,77B)(1+0,4B^{12})}N_{1,2,t} \quad (4.29)$$

$$Y_{2,2,t}^{(1)} = 1806,4t + 54075,6S_1 + 35020,7S_2 + 47027,9S_3 + 46992S_4 + 67537,1S_5 + 74009,3S_6 + 98949,2S_7 + 88480S_8 + 73048,4S_9 + 78565,4S_{10} + 73134,4S_{11} + 103911,7S_{12} - 48472,1V_{1,t-1} - 34997,8V_{2,t-1} - 14015,4V_{3,t-1} - 26938V_{3,t} - 36677V_{4,t} - 58836,8I_t^{(125)} + 41451,5I_t^{(150)} - 60809,4I_t^{(179)} + \frac{1}{(1+0,56B+0,31B^2)(1+0,47B^{12})}N_{2,2,t} \quad (4.30)$$

$$Y_{3,2,t}^{(1)} = 2213,5t + 122144,2S_1 + 98983,3S_2 + 103193,1S_3 + 99786S_4 + 109386,2S_5 + 117755,7S_6 + 139969,6S_7 + 156064,3S_8 + 140320,5S_9 + 138156,2S_{10} + 96306,2S_{11} + 95143,9S_{12} - 18119V_{1,t-1} + 20530V_{3,t-1} + 6442,1V_{3,t+1} - 140735,9I_t^{(68)} + 145843I_t^{(178)} - 48990,8I_t^{(183)} + \frac{1}{(1+0,97B)(1-0,25B^{46})}N_{3,2,t} \quad (4.31)$$

$$Y_{4,2,t}^{(1)} = 1231,3t + 123426,6S_1 + 114635,5S_2 + 122362,8S_3 + 123823,8S_4 + 129097,7S_5 + 150333,9S_6 + 176964,3S_7 + 168319,2S_8 + 158929,7S_9 + 142368,4S_{10} + 108860,6S_{11} + 137802,4S_{12} - 15134,2V_{1,t-1} + \frac{1}{(1+0,66B+0,31B^2)(1+0,2B^{10})}N_{4,2,t} \quad (4.32)$$

Data Kargo:

$$Z_{1,2,t}^{(1)} = -1,78t + 699,88S_1 + 641,38S_2 + 676,86S_3 + 707,68S_4 + 762,81S_5 + 760,09S_6 + 773,71S_7 + 716,66S_8 + 713,17S_9 + 749,37S_{10} + 733,47S_{11} + 769,56S_{12} - 90,09V_{2,t} + 615,29I_t^{(32)} - 284,84I_t^{(168)} + \frac{1}{(1+0,59B+0,25B^2)}N_{1,2,t} \quad (4.33)$$

$$Z_{2,2,t}^{(1)} = 5,17t + 660,87S_1 + 581,56S_2 + 690,37S_3 + 683,05S_4 + 726,65S_5 + 703,14S_6 + 729,71S_7 + 711,1S_8 + 781,42S_9 + 834,13S_{10} + 820,17S_{11} + 827,43S_{12} - 271,19V_{2,t} - 291,92V_{3,t} - 173,48V_{3,t} + 364,06I_t^{(12)} + 322,40I_t^{(32)} - 960,7I_t^{(167)} - 578,84I_t^{(167)} + \frac{1}{(1+0,45B+0,34B^2)}N_{2,2,t} \quad (4.34)$$

$$Z_{3,2,t}^{(1)} = -7,66t + 2766,8S_1 + 2564,5S_2 + 3159,7S_3 + 3228,8S_4 + 3058,5S_5 + 2804,6S_6 + 2762,1S_7 + 2718,9S_8 + 2805,2S_9 + 3163,6S_{10} + 3205,7S_{11} + 3231,7S_{12} - 418,58V_{1,t} - 235,5V_{2,t} - 231,38V_{3,t+1} - 321,48V_{4,t+1} + \frac{1}{(1+0,59B+0,19B^5)}N_{3,2,t} \quad (4.35)$$

$$Z_{4,2,t}^{(1)} = 2,76t + 504,96S_1 + 429,13S_2 + 593,75S_3 + 618,59S_4 + 593,09S_5 + 608,62S_6 + 628,62S_7 + 609,29S_8 + 599,41S_9 + 620,08S_{10} + 662,13S_{11} + 659,19S_{12} + 232,27V_{4,t-1} - 137,93V_{1,t} - 134,57V_{3,t} + 387,57I_t^{(17)} + 413,94I_t^{(108)} + 1310,2I_t^{(109)} + 273,43I_t^{(159)} - 669,83I_t^{(167)} + \frac{1}{(1+0,74B+0,14B^3)}N_{4,2,t} \quad (4.36)$$

Setelah diperoleh persamaan model ARIMAX untuk masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai, maka dilakukan evaluasi kebaikan model menggunakan kriteria RMSE dan MAPE untuk data *training* dan *testing* pada Tabel 4.27.

Tabel 4.27. Hasil Peramalan Model ARIMAX di Bandara I Gusti Ngurah Rai

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	16.951,93	7,28	30.376,14	5,74
Domestik datang	13.961,34	5,44	36.847,41	7,61
Internasional berangkat	15.973,90	7,59	49.333,20	7,50
Internasional datang	14.597,86	6,59	42.435,27	6,96
Kargo:				
Domestik dimuat	83,36	13,51	751,45	57,86
Domestik dibongkar	141,31	12,06	328,50	24,55
Internasional dimuat	249,31	9,82	1.008,51	36,11
Internasional dibongkar	130,59	16,10	514,81	32,95

4.3.3 Hasil Pengujian Nonlinieritas

Salah satu tujuan dari pemodelan hibrida adalah memperkecil nilai residual dari model linier *time series*. Pemodelan residualnya lebih kompleks karena mengandung komponen nonlinier, sehingga pengujian nonlinieritas perlu dilakukan. Pengujian nonlinieritas ini menggunakan input yang sama pada model linier regresi *time series* kecuali variabel *dummy*. Hal tersebut untuk memastikan apakah persamaan regresi tersebut memiliki hubungan nonlinier yang terabaikan (*neglected non linierity*). Hasil uji terasvirta untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai ditampilkan pada Tabel 4.28.

Tabel 4.28. Hasil Pengujian Nonlinieritas di Bandara I Gusti Ngurah Rai

Data	Chi-Square	df	p-value	Input
Penumpang:				
Domestik berangkat	120,67	50	0,00000	$t, Y_{1,2,t-1}, Y_{1,2,t-11}, Y_{1,2,t-12}, Y_{1,1,t-13}$
Domestik datang	47,417	30	0,02260	$t, Y_{2,2,t-1}, Y_{2,2,t-2}, Y_{2,2,t-12}$
Internasional berangkat	110,9	30	0,00000	$t, Y_{3,2,t-1}, Y_{3,2,t-3}, Y_{3,2,t-45}$
Internasional datang	51,504	16	0,00001	$t, Y_{4,2,t-1}, Y_{4,2,t-12}$
Kargo:				
Domestik dimuat	125,96	30	0,00000	$t, Z_{1,2,t-1}, Z_{1,2,t-2}, Z_{1,2,t-26}$
Domestik dibongkar	45,672	7	0,00000	$t, Z_{2,2,t-1}, Z_{2,2,t-8}$
Internasional dimuat	63,185	16	0,00000	$t, Z_{3,2,t-1}, Z_{3,2,t-5}$
Internasional dibongkar	59,906	16	0,00000	$t, Z_{4,2,t-1}, Z_{4,2,t-2}$

Tabel 4.28 menunjukkan pada pemodelan linier data penumpang dan kargo di Bandara I Gusti Ngurah Rai masih terdapat adanya komponen nonlinier yang terabaikan (*neglected nonlinierity*). Hal tersebut dikarenakan hasil pengujian teravista menunjukkan nilai *p-value* kurang dari taraf uji $\alpha = 0,05$. Sehingga dapat dikatakan bahwa untuk tahap selanjutnya layak dilakukan pemodelan dengan menggunakan metode hibrida.

4.3.4 Pemodelan Hibrida TSR-NN

Pada pemodelan hibrida TSR-NN, model pertama menggunakan metode TSR ke dalam komponen linier. Model TSR sebelumnya sudah dijelaskan pada sub bab 4.3.1. Residual dari TSR ini dianggap masih mengandung komponen non linier, sehingga residual ini dimodelkan dengan menggunakan metode FFNN dengan tiga *layer*. *Layer* pertama merupakan *layer input*, yang menggunakan *lag* yang signifikan pada pemodelan TSR. *Layer* kedua merupakan *hidden layer* yang terdiri antara 1 sampai 10 *neuron*, yang nantinya dipilih jumlah *neuron* yang menghasilkan MAPEP minimum. Sedangkan *layer* terakhir adalah *layer output*. Pada *hidden layer* menggunakan fungsi aktivasi sigmoid dan pada *output layer* menggunakan fungsi aktivasi linier

Adapun pemilihan *neuron* pada *hidden layer* dan arsitektur FFNN terbaik untuk masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai dapat dilihat lebih rinci dalam Lampiran. Hasil pemodelan hibrida TSR-NN untuk keseluruhan data I Gusti Ngurah Rai dijabarkan pada Tabel 4.29.

Tabel 4.29 Hasil Peramalan Model Hibrida TSR-NN di Bandara I Gusti Ngurah Rai

Data	Model TSR-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(4,4,1)	14.126,53	5,46	27.741,37	5,32
Domestik datang	(3,10,1)	10.554,75	4,08	32.231,35	6,26
Internasional berangkat	(3,3,1)	11.487,43	3,59	67.433,28	10,92
Internasional datang	(2,2,1)	11.994,75	5,34	32.852,97	5,70
Kargo:					
Domestik dimuat	(3,1,1)	55,74	10,11	634,90	49,19
Domestik dibongkar	(2,2,1)	129,05	10,63	192,71	13,57
Internasional dimuat	(2,4,1)	243,11	9,06	1.031,38	35,06
Internasional dibongkar	(2,4,1)	125,37	15,69	351,32	26,18

Setelah diperoleh nilai akurasi peramalan seperti pada Tabel 4.29 untuk seluruh data penumpang dan kargo di Bandara I Gusti Ngurah Rai maka secara rata-rata pada data *in-sample* model hibrida TSR-NN mampu mengurangi Nilai MAPE model TSR sebesar 40,90 persen pada data penumpang dan sebesar 26,53 persen pada data kargo. Sedangkan pada data *out-sample*, model hibrida TSR-NN mampu mengurangi Nilai MAPEP model TSR sebesar 17,25 persen pada data penumpang dan sebesar 6,07 persen pada data kargo. Hal tersebut menunjukkan bahwa penggunaan model hibrida TSR-NN mampu meningkatkan akurasi peramalan dibandingkan dengan model TSR.

4.3.5 Pemodelan Hibrida ARIMAX-NN

Model pertama yang digunakan dalam pemodelan hibrida ARIMAX-NN untuk data jumlah penumpang domestik yang berangkat dari Bandara I Gusti Ngurah Rai, adalah model ARIMAX sebagai komponen linier. Model ARIMAX yang diperoleh sudah dijelaskan sebelumnya pada sub bab 4.2.2. Residual dari ARIMAX ini dianggap masih mengandung komponen nonlinier yang kemudian dimodelkan dengan metode FFNN tiga layer

Hasil pemilihan *neuron* pada *hidden layer* beserta dengan arsitektur FFNN terbaik pada masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai secara rinci ditampilkan pada Lampiran 10B. Adapun ringkasan hasil pemodelan hibrida ARIMAX-NN untuk keseluruhan data Bandara I Gusti Ngurah Rai dijabarkan pada Tabel 4.30.

Tabel 4.30 Hasil Peramalan Model Hibrida ARIMAX-NN di Bandara I Gusti Ngurah Rai

Data	Model ARIMAX-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(2,8,1)	14424,32	5,99	29753,06	5,60
Domestik datang	(3,10,1)	9686,73	3,77	27455,86	5,41
Internasional berangkat	(2,1,1)	16124,18	6,41	48412,53	7,31
Internasional datang	(3,1,1)	14211,74	6,43	41695,03	6,65
Kargo:					
Domestik dimuat	(2,8,1)	67,22	13,18	740,46	56,47
Domestik dibongkar	(2,9,1)	114,37	9,23	309,63	23,90
Internasional dimuat	(2,5,1)	223,71	8,17	974,25	35,00
Internasional dibongkar	(2,2,1)	122,75	14,53	518,16	32,59

Setelah diperoleh nilai akurasi peramalan model ARIMAX-NN pada Tabel 4.30 untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai maka secara rata-rata pada data *in-sample* model hibrida ARIMAX-NN mampu mengurangi Nilai MAPE model ARIMAX sebesar 30,43 persen pada data penumpang dan sebesar 22,18 persen pada data kargo. Sedangkan pada data *out-sample*, model hibrida ARIMAX-NN hanya mampu mengurangi Nilai MAPEP model ARIMAX sebesar 9,59 persen untuk data penumpang dan sebesar 2,30 persen untuk data kargo. Hal tersebut menunjukkan bahwa penggunaan model hibrida ARIMAX-NN mampu meningkatkan akurasi peramalan dibandingkan dengan model ARIMAX.

4.3.6 Pemodelan Hibrida TSR-SVR

Penentuan parameter dalam pemodelan TSR-SVR adalah dengan menggunakan metode *grid search*. Metode ini bertujuan untuk memperoleh hasil estimasi yang global optimum. Input yang digunakan dalam model TSR-SVR sama dengan input yang digunakan dalam model TSR-NN. Parameter yang dimiliki model SVR ada tiga yaitu parameter *epsilon*, σ^2 , dan *C*. Kombinasi Nilai σ^2 yang digunakan antara 0,01 sampai dengan 1 (Shabri, 2015). Nilai parameter *epsilon* yang digunakan dari rentang nilai antara 10 sampai dengan 1000. Sedangkan untuk nilai *C* yang digunakan dari rentang 100 hingga 100000. Hasil peramalan TSR-SVR untuk data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai dengan menggunakan nilai parameter *epsilon*, σ^2 , dan *C* terbaik dijabarkan pada Tabel 4.31. Sedangkan hasil pencarian model terbaik masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai dapat dilihat secara rinci dalam lampiran 11B.

Tabel 4.31 Hasil Peramalan Model Hibrida TSR-SVR di Bandara I Gusti Ngurah Rai

Data	Parameter			Akurasi Peramalan			
	<i>Epsilon</i>	<i>C</i>	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	100	1000	0,05	16.772,42	5,30	34.403,44	6,95
Domestik datang	250	5000	0,05	13.261,12	3,54	39.640,41	7,19
Internasional berangkat	100	15000	0,1	20.607,70	5,78	74.722,33	12,62
Internasional datang	200	1000	0,05	11.536,77	4,88	44.012,51	7,73
Kargo:							
Domestik dimuat	100	1000	0,07	95,15	21,82	639,59	50,79
Domestik dibongkar	10	1000	0,05	75,31	6,98	270,12	19,56
Internasional dimuat	10	100	0,1	184,74	5,51	990,04	35,80
Internasional dibongkar	100	3000	0,09	77,38	11,22	421,39	31,56

Tabel 4.31 menunjukkan bahwa hasil metode *grid search* yang paling optimum untuk masing-masing data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai. Selain itu metode hibrida TSR-SVR secara rata-rata dapat mengurangi residual TSR pada data *in-sample* hingga 20,55 persen untuk data penumpang dan 16,32 persen untuk data kargo di Bandara Soekarno Hatta. Namun pada *out-sample*, hasil ramalan hibrida TSR-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik dibandingkan dengan model TSR.

4.3.7 Pemodelan Hibrida ARIMAX-SVR

Sama halnya dengan pemodelan TSR-SVR, pemodelan ARIMAX-SVR juga menggunakan metode *grid search* untuk mendapatkan hasil estimasi yang optimum. Input yang digunakan dalam model ARIMAX-SVR sama dengan input yang digunakan dalam model ARIMAX-NN. Metode *grid search* mencari kombinasi ketiga parameter *epsilon*, σ^2 , dan *C*, agar didapatkan nilai kesalahan ramalan terkecil (MAPEP) yang terkecil. Hasil pemilihan parameter untuk model terbaik dengan metode *grid search* masing-masing dapat dilihat secara rinci dalam lampiran. Hasil ramalan baik pada data *in-sample* dan *out-sample* menggunakan pemodelan ARIMAX-SVR untuk data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai dapat dilihat pada Tabel 4.32.

Tabel 4.32 Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara I Gusti Ngurah Rai

Data	Parameter			Akurasi Peramalan			
	<i>Epsilon</i>	<i>C</i>	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	100	37000	0,05	1780,38	0,16	50302,58	9,22
Domestik datang	650	5000	0,05	10627,35	3,19	45312,01	9,35
Internasional berangkat	100	83000	0,08	1175,33	0,13	50643,10	7,48
Internasional datang	100	55000	0,1	1365,78	0,10	50762,28	8,60
Kargo:							
Domestik dimuat	100	100	0,07	77,39	14,78	635,67	42,69
Domestik dibongkar	100	100	0,1	105,67	9,38	185,28	13,84
Internasional dimuat	10	100	0,05	176,79	5,17	1182,33	46,85
Internasional dibongkar	100	3000	0,06	81,30	12,73	400,25	22,90

Tabel 4.32 menampilkan hasil peramalan dengan parameter terbaik menggunakan metode *grid search* untuk pemodelan residual ARIMAX pada data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai. Berdasarkan akurasi peramalan tersebut terlihat bahwa metode hibrida ARIMAX-SVR secara rata-rata

dapat mengurangi nilai MAPE ARIMAX hingga 83,97 persen untuk data penumpang dan 20,32 persen untuk data kargo di Bandara I Gusti Ngurah Rai. Namun pada *out-sample*, hasil ramalan ARIMAX-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik dibandingkan dengan model ARIMAX.


4.3.8 Perbandingan Hasil Model Peramalan

Perbandingan hasil pemodelan TSR, ARIMAX dengan variasi kalender, hibrida TSR-NN, hibrida TSR-SVR, hibrida ARIMAX-NN dan hibrida ARIMAX-SVR pada data penumpang dan kargo di Bandara I Gusti Ngurah Rai dilakukan untuk melihat tingkat akurasi peramalan. Tabel 4.33 menampilkan perbandingan akurasi keenam model tersebut menggunakan nilai RMSEP dan MAPEP terkecil. Sedangkan pemilihan model terbaiknya berdasarkan pada nilai MAPEP.

Tabel 4.33 Hasil Akurasi Peramalan Data *Out Sample* Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara I Gusti Ngurah Rai


Data	Metode Peramalan					
	TSR	ARIMAX	TSR-NN	TSR-SVR	ARIMAX-NN	ARIMAX-SVR
Nilai RMSEP						
Penumpang Domestik						
Berangkat	31346,31	30376,14	27741,37	34403,44	29753,06	50302,58
Datang	42750,88	36847,41	32231,35	39640,41	27455,86	45312,01
Penumpang Internasional						
Berangkat	75086,48	49333,20	67433,28	74722,33	48412,53	50643,10
Datang	42054,93	42435,27	32852,97	44012,51	41695,03	50762,28
Kargo Domestik						
Berangkat	639,72	751,45	634,90	639,59	740,46	635,67
Datang	189,64	328,50	192,71	270,12	309,63	185,28
Kargo Internasional						
Berangkat	1069,14	1008,51	1031,38	990,04	974,25	1182,33
Datang	352,56	514,81	351,32	421,39	518,16	400,25
Nilai MAPEP						
Penumpang Domestik						
Berangkat	5,79	5,74	5,32	6,95	5,60	9,22
Datang	9,22	7,61	6,26	7,19	5,41	9,35
Penumpang Internasional						
Berangkat	12,43	7,50	10,92	12,62	7,31	7,48
Datang	6,84	6,96	5,70	7,73	6,65	8,60
Kargo Domestik						
Berangkat	49,43	57,86	49,19	50,79	56,47	42,69
Datang	14,75	24,55	13,57	19,56	23,90	13,84
Kargo Internasional						
Berangkat	38,73	36,11	35,06	35,80	35,00	46,00
Datang	26,35	32,95	26,18	31,56	32,59	22,90

Hasil peramalan pada *out-sample* data penumpang dan kargo di Bandara I Gusti Ngurah Rai dengan keenam metode peramalan tersebut secara visual ditampilkan pada Gambar 4.14.



Gambar 4.14. Hasil ramalan *out-sample* pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara I Gusti Ngurah Rai.

Selanjutnya Gambar 4.15 akan menunjukkan perbandingan nilai MAPEP per bulan ramalan (MAPEP *Adaptive*) dari keenam metode peramalan untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai.



Gambar 4.15. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara I Gusti Ngurah Rai.

Berdasarkan Tabel 4.33 dan Gambar 4.15, maka terlihat model terbaik menggunakan kriteria MAPEP untuk data penumpang dan kargo di Bandara I Gusti Ngurah Rai memiliki model yang berbeda-beda. Untuk pemodelan data jumlah penumpang domestik yang berangkat, jumlah penumpang internasional yang datang, dan kargo domestik yang dibongkar di Bandara I Gusti Ngurah Rai, yang memberikan akurasi terbaik adalah model TSR-NN. Model terbaik untuk data jumlah penumpang domestik yang datang, data jumlah penumpang internasional yang berangkat dan data kargo internasional yang dimuat adalah model ARIMAX-NN. Adapun untuk data kargo domestik yang dimuat dan data kargo internasional yang dibongkar, model terbaiknya adalah model ARIMAX-SVR.


4.3.9 Hasil Ramalan hingga Tahun 2018 di Bandara I Gusti Ngurah Rai

Setelah diperoleh model peramalan terbaik masing-masing data penumpang dan kargo di Bandara I Gusti Ngurah Rai, maka selanjutnya dilakukan ramalan kedepan dari September 2017 hingga Desember 2018 seperti pada Tabel 4.34.


Tabel 4.34 Angka Ramalan Penumpang Udara dan Kargo Di Bandara I Gusti Ngurah Rai Periode Bulan September 2017 hingga Desember 2018

Periode	Penumpang Domestik		Penumpang Internasional		Kargo Domestik		Kargo Internasional	
	Berangkat	Datang	Berangkat	Datang	Dimuat	Dibongkar	Dimuat	Dibongkar
	TSR-NN	ARIMAX-NN	ARIMAX-NN	TSR-NN	ARIMAX-SVR	TSR-NN	ARIMAX-NN	ARIMAX-SVR
2017								
September	460.716	477.756	489.705	487.504	20.639	5.860	12.229	12.579
Oktober	479.653	447.060	474.723	453.037	20.468	5.903	13.704	13.479
November	407.569	451.164	441.230	437.141	21.637	5.802	13.332	12.375
Desember	431.402	503.140	431.763	464.549	20.475	6.421	13.990	12.701
2018								
Januari	451.035	447.304	473.425	451.806	19.056	5.930	12.966	12.110
Februari	422.797	444.017	441.481	432.063	20.592	5.279	13.032	12.289
Maret	407.978	432.124	445.958	435.097	20.400	5.719	13.982	13.537
April	433.989	443.622	438.689	446.586	22.968	5.116	13.738	13.149
Mei	442.452	444.664	461.384	440.254	19.368	6.206	14.093	14.727
Juni	482.275	474.345	458.164	476.253	21.359	4.577	13.198	10.621
Juli	549.249	511.612	496.399	499.959	21.128	7.610	13.712	11.842
Agustus	508.002	490.589	510.733	506.194	20.983	5.202	13.457	12.027
September	476.785	472.872	490.176	495.731	21.776	4.350	13.514	14.051
Oktober	471.858	487.078	502.621	480.104	21.580	5.692	14.034	13.738
November	454.789	480.289	461.841	456.406	22.722	4.880	15.157	12.653
Desember	436.798	507.366	450.383	483.251	20.639	6.489	13.545	12.976

Sedangkan secara visual hasil ramalan untuk data penumpang di Bandara I Gusti Ngurah Rai ditampilkan pada Gambar 4.16 dan untuk data kargo di Bandara I Gusti Ngurah Rai ditampilkan pada Gambar 4.17.



Gambar 4.16 Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara I Gusti Ngurah Rai.



Gambar 4.17 Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara I Gusti Ngurah Rai

4.4 Pemodelan Bandara Internasional Juanda

Tahapan pemodelan yang dilakukan untuk data penumpang dan kargo di Bandara Internasional Juanda terdiri dari pemodelan tahap pertama dan pemodelan tahap kedua. Pemodelan tahap pertama menggunakan model TSR dan ARIMAX. Sedangkan pemodelan tahap kedua dengan metode peramalan hibrida yaitu TSR-NN, ARIMAX-NN, TSR-SVR, dan ARIMAX-SVR menggunakan input residual model tahap pertama. Dari keempat model tersebut diperoleh model terbaik, kemudian diperoleh angka prediksi 2018 dari model terbaiknya.

4.4.1 Pemodelan *Time Series Regression* (TSR)

Tahapan pemodelan regresi *time series* secara rinci telah dijelaskan sebelumnya pada sub bab 4.2.1. Tahapan tersebut antara lain terkait pemeriksaan diagnosa asumsi residual yang meliputi *white noise* dan berdistribusi normal dapat dilihat pada Lampiran 8C, serta signifikansi parameter dapat dilihat pada Lampiran 9C. Untuk pemodelan regresi *time series* pada data penumpang dan kargo di Bandara Juanda tidak semua data bebas dari asumsi residual berdistribusi normal sehingga perlu dilakukan deteksi *outlier*. Hasil pemodelan regresi *time series* yang telah memenuhi asumsi residual *white noise* dan berdistribusi normal, serta dengan parameter yang signifikan ditampilkan pada Tabel 4.35.

Tabel 4.35 Ringkasan Hasil Pengujian Asumsi Model TSR di Bandara Juanda

Data	White Noise	Data Outlier ke-	Jenis Outlier	Uji KS (<i>p-value</i>)
Penumpang:				
Domestik berangkat	YA	30, 35, 151, 158, 156, 158, 169, 170	Additive	0,0728
Domestik datang	YA	41, 158, 170	Additive	>0,1500
Internasional berangkat	YA	13, 25, 37, 72, 84, 118, 145, 152, 156, 166, 189	Additive	0,0896
Internasional datang	YA	38, 50, 96, 108, 143, 145, 147, 150, 151, 152, 155, 157, 167, 180	Additive	0,0929
Kargo:				
Domestik dimuat	YA	55, 63, 105, 153	Additive	>0,1500
Domestik dibongkar	YA	-	-	0,1144
Internasional dimuat	YA	16, 100, 140	Additive	>0,1500
Internasional dibongkar	YA	-	-	0,1294

Adapun model regresi *time series* untuk keseluruhan data penumpang dan kargo di Bandara Juanda secara matematis dapat dituliskan sebagai berikut:

Data Penumpang:

$$\begin{aligned}\hat{Y}_{1,3,t}^{(1)} = & 309,37t - 33581,3S_2 + 24837,2S_5 + 42579,3S_7 - 58463,4V_{1,t-1} - 48898,5V_{2,t-1} + \\ & 82002,1V_{1,t} + 46267,5V_{2,t} - 129212,9V_{4,t} + 31185,4V_{1,t+1} + 53669V_{3,t+1} + \\ & 79814,9V_{4,t+1} + 0,46Y_{1,3,t-1} + 0,35Y_{1,3,t-2} - 0,14Y_{1,3,t-10} + 0,25Y_{13,t-12} + \\ & 87088,7I_t^{(30)} + 107898,4I_t^{(35)} - 80192I_t^{(151)} - 96480,3I_t^{(158)} + 114856I_t^{(164)} - \\ & 77227,6I_t^{(169)} - 84082I_t^{(170)}\end{aligned}\quad (4.37)$$

$$\begin{aligned}\hat{Y}_{2,3,t}^{(1)} = & 307,98t - 45631,5S_2 + 25542,4S_5 + 38877,6S_6 + 58045,4S_7 + 21990,6S_{11} + \\ & 33443,5S_{12} - 75227,1V_{1,t-1} - 41132,6V_{2,t-1} - 40424V_{4,t} + 0,27Y_{2,3,t-1} + \\ & 0,46Y_{2,3,t-2} + 0,22Y_{2,3,t-5} + 113520,6I_t^{(41)} - 111596,2I_t^{(158)} - 134169,3I_t^{(170)}\end{aligned}\quad (4.38)$$

$$\begin{aligned}\hat{Y}_{3,3,t}^{(1)} = & 190,3t + 6504,4S_3 + 2062,4S_4 + 3764,7S_5 + 7869,3S_6 + 3705,6S_7 + 7682S_8 + \\ & 6798,9S_9 + 5781,4S_{10} + 4563,5S_{11} + 10185,8S_{12} - 5069V_{1,t-1} - 9325,7V_{2,t-1} - \\ & 6098,1V_{3,t-1} + 7720,4V_{1,t} + 6667,3V_{2,t} + 18272,2V_{2,t+1} + 9669,7V_{3,t+1} + \\ & 8966,1V_{4,t+1} + 0,30Y_{3,3,t-1} + 0,16Y_{3,3,t-12} + 228287,7I_t^{(13)} + 22055,8I_t^{(25)} + \\ & 40379,9I_t^{(37)} + 32529,9I_t^{(72)} + 18152,7I_t^{(84)} - 21727,2I_t^{(118)} + 18101,2I_t^{(145)} + \\ & 22216,4I_t^{(152)} + 18924,8I_t^{(152)} + 27281,8I_t^{(156)} - 29776,4I_t^{(188)}\end{aligned}\quad (4.39)$$

$$\begin{aligned}\hat{Y}_{4,3,t}^{(1)} = & 180,58t + 16348,5S_1 + 9105,7S_3 + 7087,6S_4 + 10209,8S_5 + 9179,6S_6 + \\ & 14831,8S_7 + 11389,5S_8 + 9730,3S_9 + 10284,8S_{10} + 12942,1S_{11} + 12809,8S_{12} - \\ & 5759,8V_{1,t+1} - 8099V_{3,t+1} + 0,09Y_{4,3,t-1} + 0,41Y_{4,t-35} + 25243,3I_t^{(38)} + \\ & 20356,9I_t^{(50)} + 24026,8I_t^{(96)} + 21100,8I_t^{(108)} + 18830,5I_t^{(143)} + 21912,9I_t^{(145)} + \\ & 13193,7I_t^{(147)} + 14816,9I_t^{(150)} + 20291,6I_t^{(151)} + 16300,9I_t^{(152)} + 16300,9I_t^{(155)} + \\ & 16080,4I_t^{(157)} - 18976,7I_t^{(167)} - 14982,2I_t^{(180)}.\end{aligned}\quad (4.40)$$

Data Kargo:

$$\begin{aligned}\hat{Z}_{1,3,t}^{(1)} = & 9,42t + 234,56S_1 + 351,06S_3 + 333,92S_4 + 404,73S_5 + 270,78S_6 + 292,73S_7 + \\ & 719,48S_{10} + 391,53S_{11} + 674,94S_{12} - 353,33V_{1,t} + 0,7Z_{1,3,t-1} - 0,2Z_{1,3,t-45} + \\ & 115,3I_t^{(55)} - 853,64I_t^{(63)} + 858,37I_t^{(105)} - 965I_t^{(153)}\end{aligned}\quad (4.41)$$

$$\begin{aligned}\hat{Z}_{2,3,t}^{(1)} = & 2,29t + 960,57S_1 + 720,58S_2 + 1085,3S_3 + 814,03S_4 + 1162S_5 + 979,04S_6 + \\ & 1121,1S_7 + 916,11S_8 + 1148,2S_9 + 972,68S_{10} + 1025,6S_{11} + 1219,1S_{12} - \\ & 367,31V_{3,t-1} - 495,88V_{1,t} + 0,65Z_{2,3,t-1} + 0,23Z_{2,3,t-21} - 0,26Z_{2,3,t-22} - \\ & 0,16Z_{2,3,t-32}\end{aligned}\quad (4.42)$$

$$\begin{aligned}\hat{Z}_{3,3,t}^{(1)} = & 0,02t + 109,5S_3 + 81,35S_6 + 69,7S_7 + 59,91S_9 + 86,16S_{10} + 71,24S_{11} + 67,32S_{12} + \\ & 0,65Z_{3,3,t-1} + 0,21Z_{3,3,t-5} + 228,77I_t^{(16)} + 227,73I_t^{(100)} - 290,55I_t^{(140)}\end{aligned}\quad (4.43)$$

$$\begin{aligned}\hat{Z}_{4,3,t}^{(1)} = & 1,26t - 173,76S_3 + 165,69S_5 + 96,60S_6 + 117,67S_{10} + 162,63S_{12} + 217,30V_{4,t-1} - \\ & 213,82V_{3,t} + 215,41V_{3,t+1} + 0,55Z_{4,3,t-1} + 0,17Z_{4,3,t-15}.\end{aligned}\quad (4.44)$$

Berikutnya setelah diperoleh persamaan model TSR untuk masing-masing data penumpang dan kargo di Bandara Juanda, maka kemudian dilakukan evaluasi

kebaikan model dengan menggunakan kriteria RMSE dan MAPE untuk data *training* dan *testing* yang ditampilkan pada Tabel 4.36.

Tabel 4.36. Hasil Peramalan Model TSR di Bandara Juanda

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	27.222,95	6,00	109.266,57	15,05
Domestik datang	31.663,38	5,92	180.583,18	25,18
Internasional berangkat	3.754,51	7,19	7.072,88	7,86
Internasional datang	4.884,69	7,38	11.405,64	12,19
Kargo:				
Domestik dimuat	310,47	8,37	699,52	16,55
Domestik dibongkar	368,32	12,08	231,66	7,16
Internasional dimuat	102,67	13,68	151,35	14,04
Internasional dibongkar	167,53	19,58	217,21	24,25

4.4.2 Pemodelan ARIMAX

Pemodelan ARIMAX yang mengandung komponen tren, musiman dan variasi kalender secara rinci telah dijabarkan pada sub bab 4.2.2. Sebelumnya data dimodelkan terlebih dahulu dengan model regresi *time series*, dan residual dari hasil pemodelan tersebut dimodelkan dengan ARIMA berdasarkan pola ACF dan PACF. Tahapan selanjutnya dilakukan pemeriksaan residual *white noise* dan berdistribusi normal. Hampir semua data penumpang dan kargo di Bandara Juanda belum bebas dari asumsi residual berdistribusi normal, Sehingga perlu dilakukan deteksi outlier. Setelah semua asumsi residual terpenuhi, maka selanjutnya dilakukan uji signifikansi parameter. Seluruh tahapan pemodelan ARIMAX pada data penumpang dan kargo di Bandara Juanda dapat dilihat di Lampiran 8C dan 9C. Ringkasan hasil pemodelan ARIMAX di Bandara Juanda dijelaskan Tabel 4.37.

Tabel 4.37 Ringkasan Hasil Pengujian Asumsi Model ARIMAX di Bandara Juanda

Data	Model ARIMAX	White Noise	Data Additive Outlier ke-	Uji KS (<i>p-value</i>)
Penumpang:				
Domestik berangkat	(2,0,0)(2,0,0) ¹²	YA	126, 164	>0,1500
Domestik datang	(1,0,0)(1,0,0) ¹²	YA	36, 70, 96, 105, 129, 150, 162, 168, 180	0,1416
Internasional berangkat	(1,0,0)(1,0,0) ¹²	YA	2, 13, 25, 37, 44, 72, 84, 145, 152, 153, 156, 166	0,1045
Internasional datang	(1,0,0)([1,3],0,0) ¹²	YA	3, 15, 38, 50, 61, 143	0,1111
Kargo:				
Domestik dimuat	(1,0,0)	YA	93, 96, 104, 107, 149	0,1017
Domestik dibongkar	([1,2,22],0,0)	YA	38, 40, 41, 42, 61, 82, 108, 115	0,0735
Internasional dimuat	(2,0,0)	YA	-	>0,1500
Internasional dibongkar	(1,0,0)	YA	108	>0,1500

Representasi model ARIMAX secara matematis untuk data penumpang dan kargo di Bandara Juanda adalah sebagai berikut:

Data Penumpang:

$$Y_{1,3,t}^{(1)} = 3868,6t - 33313,7S_2 + 29977,5S_7 - 66526,7V_{1,t-1} - 61924,2V_{2,t-1} - 77870,6V_{4,t} + \frac{1}{(1-0,45B+0,4B^2)(1+0,69B^{12}-0,33B^{24})} N_{1,3,t} \quad (4.45)$$

$$Y_{2,3,t}^{(1)} = 4366,7t + 53291,6S_1 + 38557,8S_5 + 33931S_6 + 66835,3S_7 + 32914,6S_8 + 32410,4S_{10} + 42674,1S_{11} + 72947,2S_{12} - 76963V_{1,t-1} - 44116,4V_{2,t-1} - 63221,9V_{4,t} - 53935,2V_{1,t+1} - 34978,8V_{3,t+1} - 46875,5I_t^{(36)} - 72556,3I_t^{(70)} - 83278,2I_t^{(96)} - 47155,8I_t^{(105)} + 89079,6I_t^{(129)} + 64795,2I_t^{(150)} + 53991,1I_t^{(162)} + 95475,6I_t^{(168)} + 101507,9I_t^{(180)} + \frac{1}{(1+0,89B)(1+0,48B^{12})} N_{2,3,t} \quad (4.46)$$

$$Y_{3,3,t}^{(1)} = 255,11t + 22054,9S_1 + 15677,7S_2 + 17702,6S_3 + 13854,3S_4 + 14254,1S_5 + 17571,1S_6 + 15903,2S_7 + 18232,5S_8 + 19403,7S_9 + 18917,1S_{10} + 20170,4S_{11} + 29348S_{12} - 16039,1V_{1,t+1} + 36456,7I_t^{(2)} + 20991,5I_t^{(13)} + 32357,7I_t^{(25)} + 38498,7I_t^{(37)} + 9843,3I_t^{(44)} + 24546,5I_t^{(72)} + 8795,7I_t^{(145)} + 21121,3I_t^{(152)} + 27454,8I_t^{(153)} + 11257,9I_t^{(156)} + 25062,9I_t^{(166)} + \frac{1}{(1+0,29B)(1+0,5B^{12})} N_{3,3,t} \quad (4.47)$$

$$Y_{4,3,t}^{(1)} = 251,27t + 13019,1S_1 + 5651,3S_7 + 5488,8S_{11} + 8821,7S_{12} - 6710,9V_{3,t+1} + 20343,5I_t^{(3)} + 28490,2I_t^{(15)} + 22125,1I_t^{(38)} + 24722,4I_t^{(50)} - 20195,7I_t^{(61)} + 10686,1I_t^{(143)} + \frac{1}{(1+0,36B)(1+0,53B^{12}-0,35B^{36})} N_{4,3,t} \quad (4.48)$$

Data Kargo:

$$Z_{1,3,t}^{(1)} = 18,46t + 1141,6S_1 + 718,94S_2 + 749,83S_3 + 775,28S_4 + 847,33S_5 + 874,96S_6 + 1011,9S_7 + 983,68S_8 + 735,76S_9 + 1048,5S_{10} + 1141,9S_{11} + 1425,6S_{12} - 534,78V_{1,t} - 421,17V_{3,t} - 642,44V_{1,t+1} - 375,21V_{3,t+1} - 534,31I_t^{(93)} - 949,35I_t^{(96)} - 1186,9I_t^{(104)} - 858,92I_t^{(107)} + 582,69I_t^{(149)} + \frac{1}{(1+0,87B)} N_{1,3,t} \quad (4.49)$$

$$Z_{2,3,t}^{(1)} = 9,03t + 1315,4S_1 + 1110,2S_2 + 1240,1S_3 + 1104,7S_4 + 1218,6S_5 + 1215,1S_6 + 1297,5S_7 + 1201,1S_8 + 1362S_9 + 1271,7S_{10} + 1286,9S_{11} + 1461,3S_{12} - 295,65V_{1,t+1} + 576,31I_t^{(38)} + 942,6I_t^{(40)} + 1131,2I_t^{(41)} + 1129,9I_t^{(42)} + 1009,3I_t^{(61)} + 872,7I_t^{(82)} + 1080,5I_t^{(108)} + 1433,1I_t^{(115)} + \frac{1}{(1+0,46B+0,45B^2-0,1B^{22})} N_{2,3,t} \quad (4.50)$$

$$Z_{3,3,t}^{(1)} = 1,34t + 555,52S_1 + 460,58S_2 + 558,5S_3 + 519,4S_4 + 523,46S_5 + 562,52S_6 + 556,76S_7 + 522,58S_8 + 530,01S_9 + 566,51S_{10} + 584,59S_{11} + 596,19S_{12} + \frac{1}{(1+0,60B+0,19B^2)} N_{3,3,t} \quad (4.51)$$

$$Z_{4,3,t}^{(1)} = 3,1t + 340,88S_1 + 229,98S_2 + 391,3S_3 + 336,14S_4 + 426,17S_5 + 425,39S_6 + 401,86S_7 + 338,26S_8 + 312,12S_9 + 397,6S_{10} + 392,79S_{11} + 402,37S_{12} + 234,81V_{4,t-1} - 225,34V_{3,t} + 984,8I_t^{(108)} + \frac{1}{(1+0,55B)} N_{4,3,t} \quad (4.52)$$

Tahapan selanjutnya adalah melakukan evaluasi hasil peramalan model ARIMAX menggunakan kriteria RMSE dan MAPE untuk data *training* dan *testing* yang ditampilkan pada Tabel 4.38.

Tabel 4.38. Hasil Peramalan Model ARIMAX di Bandara Juanda

Data	RMSE	MAPE	RMSEP	MAPEP
Penumpang:				
Domestik berangkat	31.493,01	7,43	134.945,77	21,30
Domestik datang	27.265,88	5,86	63.665,98	6,55
Internasional berangkat	5.053,73	9,34	6.101,06	6,89
Internasional datang	7.269,60	13,77	8.321,47	8,75
Kargo:				
Domestik dimuat	304,56	9,77	899,77	23,76
Domestik dibongkar	273,76	10,06	413,30	12,28
Internasional dimuat	106,47	14,73	180,32	16,00
Internasional dibongkar	143,86	20,58	178,02	19,57

4.4.3 Hasil Pengujian Nonlinieritas

Peramalan model hibrida bekerja dengan cara memperkecil nilai residual dari model linier yang dalam penelitian ini menggunakan metode regresi *time series* dan ARIMAX, sehingga akan menghasilkan ramalan yang lebih akurat. Pemodelan residual dari model linier tersebut menggunakan pendekatan *machine learning* NN dan SVR. Oleh karena itu, sebelum melanjutkan ke dalam model hibrida perlu dilakukan adanya pengujian nonlinieritas. Penelitian ini menggunakan uji terasvirta untuk menguji apakah model linier tersebut memiliki hubungan nonlinier yang terabaikan (*neglected nonlinierity*). Pengujian nonlinieritas ini menggunakan prediktor yang sama dengan model regresi *time series* kecuali variabel *dummy*. Hasil uji terasvirta untuk data penumpang dan kargo di Bandara Juanda dijabarkan pada Tabel 4.39.

Tabel 4.39 Hasil Pengujian Nonlinieritas di Bandara Juanda

Data	Chi-Square	df	p-value	Prediktor
Penumpang:				
Domestik berangkat	122,76	50	0,00000	$t, Y_{1,3,t-1}, Y_{1,3,t-2}, Y_{1,3,t-10}, Y_{1,3,t-12}$
Domestik datang	60,818	30	0,00073	$t, Y_{2,3,t-1}, Y_{2,3,t-2}, Y_{2,3,t-5}$
Internasional berangkat	42,761	16	0,00030	$t, Y_{3,3,t-1}, Y_{3,3,t-12}$
Internasional datang	48,737	16	0,00004	$t, Y_{4,3,t-1}, Y_{4,3,t-35}$
Kargo:				
Domestik dimuat	42,719	16	0,00031	$t, Z_{1,3,t-1}, Z_{1,3,t-45}$
Domestik dibongkar	65,732	30	0,00018	$t, Z_{2,3,t-1}, Z_{2,3,t-21}, Z_{2,3,t-22}, Z_{2,3,t-32}$
Internasional dimuat	30,397	16	0,01605	$t, Z_{3,3,t-1}, Z_{3,3,t-5}$
Internasional dibongkar	43,026	16	0,00028	$t, Z_{4,2,t-1}, Z_{4,2,t-2}$

Berdasarkan pada Tabel 4.39, terlihat bahwa dalam model linier masing-masing data penumpang dan kargo di Bandara Juanda masih terdapat adanya komponen nonlinier yang terabaikan (*neglected nonlinierity*). Hal tersebut dikarenakan hasil pengujian teravista menunjukkan nilai *p-value* kurang dari taraf uji $\alpha = 0,05$. Oleh karena itu maka untuk tahap pemodelan selanjutnya layak dilakukan pemodelan dengan menggunakan model peramalan hibrida.

4.4.4 Pemodelan Hibrida TSR-NN

Pada pemodelan hibrida TSR-NN untuk data penumpang dan kargo di Bandara Juanda, model pertama menggunakan metode regresi *time series* sebagai model linier yang sebelumnya telah dijabarkan pada sub bab 4.4.1. Residual dari model tersebut dianggap masih mengandung komponen non linier, sehingga residual ini dimodelkan dengan menggunakan metode FFNN dengan tiga *layer*. Input yang digunakan adalah residual dari TSR dengan menggunakan lag yang signifikan dalam pemodelan TSR itu sendiri. Sedangkan pada *hidden layer* awalnya terdiri antara 1 sampai 10 *neuron*, yang nantinya dipilih jumlah *neuron* yang menghasilkan MAPEP terkecil. Pada *hidden layer* menggunakan fungsi aktivasi sigmoid dan pada *output layer* menggunakan fungsi aktivasi linier.

Adapun pemilihan *neuron* pada *hidden layer* dan arsitektur FFNN terbaik untuk data penumpang dan kargo di Bandara Juanda secara rinci ditampilkan dalam Lampiran. Sedangkan nilai ramalan baik pada data *in-sample* maupun *out-sample* menggunakan arsitektur TSR-NN terbaik untuk data penumpang dan kargo di Bandara Juanda dapat dilihat pada Tabel 4.40.

Tabel 4.40 Hasil Peramalan Model Hibrida TSR-NN di Bandara Juanda

Data	Model TSR-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(4,3,1)	25,362,32	5,11	104,367,79	14,02
Domestik datang	(3,9,1)	23,785,61	4,50	168,570,43	23,07
Internasional berangkat	(2,4,1)	3,465,09	6,51	6,974,59	7,49
Internasional datang	(2,2,1)	4,367,53	5,84	10,996,00	11,32
Kargo:					
Domestik dimuat	(2,6,1)	249,53	6,32	677,28	15,78
Domestik dibongkar	(4,1,1)	353,44	11,42	211,68	6,59
Internasional dimuat	(2,10,1)	85,76	11,38	126,58	12,41
Internasional dibongkar	(2,4,1)	146,12	16,97	211,26	23,63

Tabel 4.40 menjelaskan nilai akurasi peramalan pada data penumpang dan kargo di Bandara Juanda, sehingga secara rata-rata pada data *in-sample* model hibrida TSR-NN mampu mereduksi Nilai MAPE model TSR sebesar 21,44 persen pada data penumpang dan sebesar 18,42 persen pada data kargo. Sedangkan untuk data *out-sample* penumpang dan kargo di Bandara Juanda, model hibrida TSR-NN hanya mampu mereduksi Nilai MAPEP model TSR sebesar 7,25 persen untuk data penumpang dan sebesar 7,33 persen untuk data kargo.

4.4.5 Pemodelan Hibrida ARIMAX-NN

Dalam pemodelan hibrida ARIMAX-NN, model pertama menggunakan metode ARIMAX dengan komponen tren, musiman dan efek variasi kalender hari raya Idul Fitri ke dalam komponen linier. Model ARIMAX yang diperoleh sudah dijelaskan sebelumnya pada sub bab 4.4.2. Residual dari model ARIMAX tersebut dianggap masih mengandung komponen nonlinier, sehingga residual model tersebut dimodelkan dengan menggunakan metode FFNN dengan tiga layer. Hasil pemilihan *neuron* pada *hidden layer* berdasarkan nilai MAPEP minimum beserta dengan arsitektur FFNN terbaik pada masing-masing data penumpang dan kargo di Bandara Juanda secara rinci ditampilkan dalam Lampiran 10C. Adapun hasil peramalan model ARIMAX-NN menurut kriteria RMSE dan MAPE baik pada data training dan testing dengan arsitektur FFNN terbaik untuk data penumpang dan kargo di Bandara Juanda dijabarkan pada Tabel 4.41.

Tabel 4.41 Hasil Peramalan Model Hibrida ARIMAX-NN di Bandara Juanda

Data	Model ARIMAX-NN	RMSE	MAPE	RMSEP	MAPEP
Penumpang:					
Domestik berangkat	(4,3,1)	28153,69	5,73	132359,02	20,87
Domestik datang	(2,7,1)	24281,61	4,18	58259,83	6,30
Internasional berangkat	(2,8,1)	3850,76	6,85	5111,00	5,88
Internasional datang	(3,3,1)	6322,77	9,36	7814,38	7,13
Kargo:					
Domestik dimuat	(1,6,1)	285,52	9,12	848,14	21,99
Domestik dibongkar	(3,2,1)	266,50	8,93	415,46	12,44
Internasional dimuat	(2,6,1)	97,37	13,08	163,03	13,54
Internasional dibongkar	(1,3,1)	136,08	19,25	165,35	16,83

Setelah diperoleh nilai akurasi peramalan pada data penumpang dan kargo di Bandara Juanda seperti pada Tabel 4.41, maka secara rata-rata pada data *in-sample*

model hibrida ARIMAX-NN mampu mengurangi Nilai MAPE model TSR sebesar 38,39 persen pada data penumpang dan sebesar 9,79 persen pada data kargo. Sedangkan untuk data *out-sample* penumpang dan kargo di Bandara Juanda, model ARIMAX-NN hanya mampu mengurangi Nilai MAPEP model TSR sebesar 11,45 persen untuk data penumpang dan sebesar 10,29 persen untuk data kargo.

4.4.6 Pemodelan Hibrida TSR-SVR

Pemilihan parameter dalam pemodelan TSR-SVR untuk data penumpang dan kargo di Bandara Juanda menggunakan metode *grid search*. Metode ini bertujuan untuk mendapatkan hasil yang global optimum. Adapun input yang digunakan dalam model TSR-SVR sama dengan input yang digunakan dalam model TSR-NN. Untuk mendapatkan parameter yang optimum yaitu parameter *epsilon*, σ^2 , dan *C*, perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai MAPEP minimum. Kombinasi nilai parameter *epsilon* yang digunakan dari rentang nilai antara 10 sampai dengan 100. Nilai σ^2 yang digunakan antara 0,01 sampai dengan 0,1. Sedangkan untuk nilai *C* yang digunakan dari rentang 1000 hingga 100000.

Hasil peramalan hibrida TSR-SVR untuk keseluruhan data Bandara Juanda dengan menggunakan nilai parameter *epsilon*, σ^2 , dan *C* terbaik masing-masing dijabarkan pada Tabel 4.42. Sedangkan hasil pencarian model terbaiknya dengan metode *grid search* masing-masing data penumpang udara dan kargo dapat dilihat secara rinci dalam lampiran 11C.

Tabel 4.42 Hasil Peramalan Model Hibrida TSR-SVR di Bandara Juanda

Data	Parameter			Akurasi Peramalan			
	<i>Epsilon</i>	<i>C</i>	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	100	97000	0,1	1491,24	0,05	89372,08	9,49
Domestik datang	100	99000	0,05	2062,36	0,05	91660,63	10,57
Internasional berangkat	1000	7000	0,05	1062,13	2,28	9349,25	9,29
Internasional datang	100	3000	0,1	3159,35	2,80	7552,48	8,80
Kargo:							
Domestik dimuat	100	1000	0,08	88,88	2,69	482,74	10,28
Domestik dibongkar	100	1000	0,1	93,53	4,02	298,39	10,09
Internasional dimuat	10	1000	0,07	9,80	1,64	148,26	15,69
Internasional dibongkar	21	1000	0,1	19,93	3,25	216,30	20,21

Tabel 4.42 menunjukkan bahwa metode *grid search* mampu menghasilkan model yang paling optimum. Selain itu metode hibrida TSR-SVR secara rata-rata dapat mengurangi residual TSR pada data *in-sample* hingga 82,17 persen untuk data penumpang dan 76,51 persen untuk data kargo di Bandara Juanda. Namun pada *out-sample*, hasil ramalan hibrida TSR-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik dibandingkan dengan model TSR.

4.4.7 Pemodelan Hibrida ARIMAX-SVR

Sama halnya dengan pemodelan TSR-SVR, dalam pemodelan ARIMAX-SVR penentuan ketiga parameter yaitu *epsilon*, σ^2 , dan *C* juga menggunakan metode *grid search* untuk mendapatkan hasil yang global optimum. Input yang digunakan dalam model ARIMAX-SVR sama dengan input yang digunakan dalam model ARIMAX-NN. Hasil pemodelan ARIMAX-SVR untuk data penumpang dan kargo di Bandara Juanda dengan menggunakan nilai parameter *epsilon*, σ^2 , dan *C* terbaik masing-masing dapat dilihat pada Tabel 4.43. Sedangkan pemilihan parameter untuk model terbaik dengan metode *grid search* masing-masing dapat dilihat secara rinci dalam lampiran 11C.

Tabel 4.43 Hasil Peramalan Model Hibrida ARIMAX-SVR di Bandara Juanda

Data	Parameter			Akurasi Peramalan			
	<i>Epsilon</i>	<i>C</i>	σ^2	RMSE	MAPE	RMSEP	MAPEP
Penumpang:							
Domestik berangkat	100	37000	0,05	12258,43	0,96	68035,15	7,16
Domestik datang	1000	29000	0,07	10051,03	1,09	51727,63	5,51
Internasional berangkat	250	1000	0,05	4373,25	6,50	9192,17	9,17
Internasional datang	1000	1000	0,05	6266,79	8,71	8987,65	10,23
Kargo:							
Domestik dimuat	750	1000	0,07	351,24	11,04	429,04	7,97
Domestik dibongkar	400	1000	0,05	228,59	8,54	244,61	7,73
Internasional dimuat	300	1000	0,05	113,66	17,09	169,65	17,42
Internasional dibongkar	100	5000	0,05	19,93	3,25	216,30	20,21

Dari Tabel 4.43 terlihat bahwa metode *grid search* mampu menghasilkan model yang paling optimum. Selain itu metode hibrida ARIMAX-SVR secara rata-rata dapat mengurangi residual ARIMAX pada data *in-sample* hingga 58,93 persen untuk data penumpang dan 3,30 persen untuk data kargo di Bandara Juanda. Namun pada *out-sample*, hasil ramalan hibrida TSR-SVR tidak selalu menghasilkan akurasi peramalan yang lebih baik dibandingkan dengan model TSR.


4.4.8 Perbandingan Hasil Model Peramalan

Perbandingan hasil pemodelan TSR, ARIMAX dengan variasi kalender, hibrida TSR-NN, hibrida TSR-SVR, hibrida ARIMAX-NN dan hibrida ARIMAX-SVR pada data penumpang dan kargo di Bandara Juanda dilakukan dengan melihat tingkat akurasi peramalan. Tabel 4.44 menampilkan perbandingan akurasi keenam model tersebut menggunakan nilai RMSE dan MAPE terkecil baik pada *out-sample*. Pemilihan model terbaiknya menggunakan nilai MAPEP.

Tabel 4.44 Hasil Akurasi Peramalan Data *Out-Sample* Model TSR, ARIMAX, TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR Data Penumpang dan Kargo di Bandara Juanda


Data	Metode Peramalan					
	TSR	ARIMAX	TSR-NN	TSR-SVR	ARIMAX-NN	ARIMAX-SVR
Nilai RMSEP						
Penumpang Domestik						
Berangkat	109266,57	134945,77	104367,79	89372,08	132359,02	68035,15
Datang	180583,18	63665,98	168570,43	91660,63	58259,83	51727,63
Penumpang Internasional						
Berangkat	7072,88	6101,06	6974,59	9349,25	5111,00	9192,17
Datang	11405,64	8321,47	10996,00	7552,48	7814,38	8987,65
Kargo Domestik						
Berangkat	699,52	899,77	677,28	482,74	848,14	429,04
Datang	231,66	413,30	211,68	298,39	415,46	244,61
Kargo Internasional						
Berangkat	151,35	180,32	126,58	148,26	163,03	169,65
Datang	217,21	178,02	211,26	216,30	165,35	175,57
Nilai MAPEP						
Penumpang Domestik						
Berangkat	15,05	21,30	14,02	9,49	20,87	7,16
Datang	25,18	6,55	23,07	10,57	6,30	5,51
Penumpang Internasional						
Berangkat	7,86	6,89	7,49	9,29	5,88	9,17
Datang	12,19	8,75	11,32	8,80	7,13	10,23
Kargo Domestik						
Berangkat	16,55	23,76	15,78	10,28	21,99	7,97
Datang	7,16	12,28	6,59	10,09	12,44	7,73
Kargo Internasional						
Berangkat	14,04	16,00	12,41	15,69	13,54	17,42
Datang	24,25	19,57	23,63	20,21	16,83	16,93

Hasil peramalan pada *out-sample* data penumpang dan kargo di Bandara Juanda dengan keenam metode peramalan tersebut secara visual ditampilkan pada Gambar 4.18.



Gambar 4.18. Hasil ramalan *out-sample* pada data penumpang domestik yang berangkat (a) dan datang (b); data penumpang internasional yang berangkat (c) dan datang (d); data kargo domestik yang dimuat (e) dan dibongkar (f); serta data kargo internasional yang dimuat (g) dan dibongkar (h) di Bandara Juanda.

Selanjutnya Gambar 4.19 akan menunjukkan perbandingan nilai MAPEP per bulan ramalan (MAPEP *Adaptive*) dari keenam metode peramalan untuk data penumpang dan kargo di Bandara Juanda.



Gambar 4.19. Perbandingan nilai MAPEP bulan ramalan pada data penumpang udara dan kargo di Bandara Juanda.

Tabel 4.44 dan Gambar 4.19 menunjukkan bahwa model terbaik untuk masing-masing data penumpang dan kargo di Bandara Juanda memiliki model yang berbeda-beda. Pada pemodelan data jumlah penumpang domestik yang berangkat,

data jumlah penumpang domestik yang datang dan data kargo domestik yang dimuat dari Bandara Juanda, yang memberikan akurasi terbaik adalah model ARIMAX-SVR. Model terbaik untuk data penumpang internasional yang berangkat, data jumlah penumpang internasional yang datang, dan data kargo internasional yang dibongkar di Bandara Juanda adalah model ARIMAX-NN. Sedangkan model terbaik untuk data kargo domestik yang dibongkar dan data kargo internasional yang dimuat adalah model TSR-NN.


4.4.9 Hasil Ramalan hingga Tahun 2018 di Bandara Juanda

Setelah diperoleh model peramalan terbaik untuk masing-masing data penumpang dan kargo di Bandara Juanda, maka selanjutnya dilakukan ramalan kedepan dari September 2017 hingga Desember 2018. Angka ramalan tersebut disajikan pada Tabel 4.45.


Tabel 4.45 Angka Ramalan Penumpang Udara dan Kargo Di Bandara Juanda Periode Bulan September 2017 hingga Desember 2018

Periode	Penumpang Domestik		Penumpang Internasional		Kargo Domestik		Kargo Internasional	
	Berangkat	Datang	Berangkat	Datang	Dimuat	Dibongkar	Dimuat	Dibongkar
	TSR-NN	ARIMAX-NN	ARIMAX-NN	TSR-NN	ARIMAX-SVR	TSR-NN	ARIMAX-NN	ARIMAX-SVR
2017								
September	828.800	878.396	78.983	75.536	4.438	3.030	822	892
Oktober	824.940	939.266	78.284	85.897	5.424	2.967	883	981
November	831.476	921.387	73.770	77.433	5.672	2.903	967	979
Desember	904.924	965.825	89.219	80.307	5.415	3.212	909	992
2018								
Januari	846.011	951.010	79.482	93.673	5.829	3.057	865	934
Februari	713.927	932.948	75.681	90.070	3.484	2.781	845	826
Maret	893.407	843.602	80.742	84.093	3.804	3.131	976	990
April	831.908	923.258	75.076	88.294	4.884	2.677	921	938
Mei	835.515	985.647	74.155	86.133	4.972	3.128	876	1.031
Juni	821.827	983.121	79.060	85.860	4.240	3.379	975	1.034
Juli	866.461	966.948	81.092	86.242	5.026	3.192	896	1.013
Agustus	846.540	1.015.044	75.878	89.601	4.917	2.949	939	953
September	866.954	964.123	76.736	84.508	4.340	3.118	896	930
Oktober	904.532	979.987	73.210	89.598	5.026	2.981	968	1.018
November	836.332	965.796	80.658	79.385	5.201	2.888	1.026	1.016
Desember	895.186	989.803	92.818	96.989	5.522	3.141	1.018	1.029

Secara visual hasil peramalan hingga tahun 2018 tersebut untuk data penumpang di Bandara Juanda ditampilkan pada Gambar 4.20 dan untuk data kargo di Bandara Juanda ditampilkan pada Gambar 4.21.




Gambar 4.20 Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) di Bandara Juanda.



Gambar 4.21 Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) di Bandara Juanda.

4.5 Prediksi Kumulatif Penumpang Udara dan Kargo Hingga Tahun 2018


Setelah diperoleh angka prediksi data penumpang dan kargo hingga tahun 2018 di masing-masing Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai dan Bandara Juanda, maka akan diperoleh nilai kumulatif prediksi jumlah penumpang dan kargo ketiga bandara tersebut. Angka prediksi kumulatif jumlah penumpang ketiga bandara tersebut ditampilkan Gambar 4.22.



Gambar 4.22 Angka Prediksi Jumlah Penumpang Domestik yang Berangkat (a) dan Datang (b), serta Jumlah Penumpang Internasional yang Berangkat (c) dan Datang (d) Kumulatif Tiga Bandara

Berdasarkan pada Gambar 4.22, diperkirakan terjadi peningkatan pergerakan jumlah penumpang yang tinggi pada Bulan Desember Tahun 2018 baik pada rute domestik maupun rute internasional karena adanya Libur Natal dan Tahun Baru. Selain itu juga permintaan peningkatan juga diperkirakan tinggi dari pegawai pemerintahan dan swasta dalam melakukan perjalanan dinas di akhir tahun. Sedangkan pada bulan Februari 2018 pergerakan penumpang diperkirakan menurun, secara umum jika tidak terjadi event besar, jumlah hari dalam bulan ini lebih sedikit dibandingkan bulan lainnya. Hari Raya Idul Fitri Tahun 2018 diperkirakan pada minggu kedua Bulan Juni, sehingga diperkirakan mulai terjadi

peningkatan penumpang dari Bulan Mei, Juni, dan Juli. Secara visual angka prediksi volume kargo kumulatif tiga bandara ditampilkan pada Gambar 4.23.




Gambar 4.23 Angka Prediksi Volume Kargo Domestik yang Dimuat (a) dan Dibongkar (b), serta Volume Kargo Internasional yang Dimuat (c) dan Dibongkar (d) Kumulatif Tiga Bandara

Berbeda dengan prediksi angka penumpang udara, Gambar 4.23 menunjukkan prediksi angka kargo udara yang cenderung berfluktuasi. Hal tersebut diperkirakan karena permintaan volume perdagangan berdasarkan pada kondisi perekonomian global.

4.6 Ringkasan Hasil Analisis Tiga Bandara Internasional di Indonesia

Berdasarkan kriteria nilai MAPEP untuk data penumpang udara dan kargo di masing-masing Bandara Soekarno Hatta, Bandara I Gusti Ngurah Rai, dan Bandara Juanda, diketahui bahwa hasil ramalan terbaik untuk masing-masing data tersebut pada ketiga Bandara tersebut menghasilkan model peramalan yang berbeda-beda. Frekuensi metode terbaik untuk setiap data penumpang udara dan kargo dapat diilustrasikan kedalam Gambar 4.24.



Gambar 4.24 Frekuensi Model Terbaik Berdasarkan kriteria MAPE Pada data *In-Sample* Penumpang (a) dan Kargo (c), serta Data *Out-Sample* Penumpang (b) dan Kargo (d)

Frekuensi model terbaik yang divisualisasikan pada Gambar 4.24, memperlihatkan bahwa pada *in-sample* berdasarkan kriteria MAPE untuk data penumpang udara dan kargo model TSR-SVR merupakan model peramalan terbaik. Meskipun pada *out-sample* model TSR-SVR tidak memiliki performansi yang baik dibandingkan model lainnya.

Adapun model yang terbaik untuk data *out-sample* berdasarkan kriteria MAPEP dapat meramalkan 6 data penumpang dan 3 data kargo pada tiga bandara tersebut dengan akurat adalah model ARIMAX-NN atau sebesar 38 persen. Sedangkan model TSR-NN merupakan model terbaik di *out-sample* dalam meramalkan 3 data penumpang dan 5 data kargo, atau sebesar 21 persen. Model ARIMAX-SVR merupakan model terbaik untuk data *out-sample* dalam meramalkan 3 data penumpang dan 4 data kargo. Hal ini menunjukkan bahwa penggunaan model hibrida SVR pada data *in-sample* mampu memberikan akurasi peramalan, namun pada data *out-sample* akurasi peramalannya tidak lebih akurat dibanding penggunaan model hibrida NN untuk data penumpang udara dan kargo pada tiga bandara internasional terbesar di Indonesia.

Halaman ini sengaja dikosongkan

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan, maka kesimpulan yang diperoleh dari penelitian ini adalah sebagai berikut:

- 1) Perkembangan pergerakan penumpang dan kargo di tiga bandara yaitu Bandara Internasional Soekarno Hatta, Bandara Internasional I Gusti Ngurah Rai, dan Bandara Internasional Juanda menunjukkan bahwa data tersebut memiliki pola kenaikan dari tahun ke tahun (*trend*). Selain itu pola pergerakan penumpang udara dan kargo di tiga bandara tersebut memiliki pola periodik dengan periode yang sama yaitu saat bulan Juli libur tahun ajaran baru serta bulan Desember libur Natal dan Tahun Baru. Pergerakan pola penumpang udara dan kargo juga mengalami efek peningkatan berkaitan terjadi Hari Raya Idul Fitri yang dikenal sebagai efek variasi kalender. Waktu kejadian hari terjadinya Hari Raya Idul Fitri memiliki pola yang bervariasi dari bulan ke bulan dan tahun ke tahun.
- 2) Pemodelan hibrida dengan empat metode yaitu hibrida TSR-NN, TSR-SVR, ARIMAX-NN dan ARIMAX-SVR, mampu secara signifikan mengurangi nilai residual dari model tahap pertama TSR atau ARIMAX pada data *in-sample*. Pada data penumpang di tiga bandara tersebut secara rata-rata masing-masing metode hibrida mampu mengurangi nilai MAPE dari model tahap pertamanya sebesar 36,52 persen untuk model TSR-NN, 35,73 persen untuk model ARIMAX-NN, 45,13 persen untuk model TSR-SVR dan 49,24 persen untuk model ARIMAX-SVR. Sedangkan untuk data kargo di tiga bandara tersebut metode hibrida mampu mengurangi nilai MAPE dari model tahap pertamanya sebesar 20,84 persen untuk model TSR-NN, 19,14 persen untuk model ARIMAX-NN, 50,96 persen untuk model TSR-SVR dan 19,98 persen untuk model ARIMAX-SVR. Meskipun pada *out-sample* tidak selalu menghasilkan akurasi peramalan yang lebih baik.

- 3) Pada pemodelan hibrida TSR-NN dan hibrida ARIMAX-NN, pemilihan input serta jumlah *neuron* pada *hidden layer* yang tepat. Sedangkan pada pemodelan hibrida TSR-SVR dan hibrida ARIMAX-SVR, pemilihan nilai parameter *epsilon*, σ^2 , dan *C* yang tepat akan memperoleh hasil model yang global optimum.
- 4) Dari hasil pemodelan dan peramalan menggunakan empat metode tersebut, maka berdasarkan nilai MAPEP, model ARIMAX-NN menghasilkan kinerja peramalan yang lebih baik pada 9 data penumpang dan kargo di tiga bandara tersebut. Model terbaik dengan menggunakan TSR-NN terdapat 8 data penumpang dan kargo di tiga bandara tersebut. Sedangkan model terbaik dengan menggunakan metode ARIMAX-SVR terdapat sebanyak 7 data penumpang dan kargo di tiga bandara tersebut. Hal tersebut menunjukkan bahwa penggunaan model hibrida NN lebih akurat dalam meramalkan data penumpang udara dan kargo di tiga bandara tersebut dibandingkan penggunaan model hibrida SVR.

5.2 Saran

Saran yang dapat diberikan oleh peneliti untuk pengembangan penelitian ini lebih lanjut antara lain:

- 1) Untuk peningkatan kinerja peramalan pada data penumpang udara dan kargo, dapat dilakukan dengan melibatkan faktor eksogen lainnya seperti efek cuaca, erupsi gunung api atau kebijakan pemerintah terkait regulasi harga penerbangan. Karena keterlibatan variabel eksogen dalam pemodelan bisa menurunkan nilai MAPE terutama pada data *in-sample*.
- 2) Pada penelitian dengan model peramalan hibrida biasanya menggunakan evaluasi dengan peramalan titik. Oleh karena itu, saran untuk penelitian selanjutnya dapat dilakukan peramalan interval. Untuk data ekonomi khususnya peramalan pada data penumpang udara dan kargo, peramalan interval dapat digunakan untuk memberi tingkat kepercayaan kepada para *stakeholder* bahwa prakiraan akan berada dalam interval tertentu dan memungkinkan untuk evaluasi dari ketidakpastian di masa depan.

DAFTAR PUSTAKA

- Amjady, N., Daraeepour, A., dan Keynia, F. (2010). Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network. *IET generation, transmission and distribution*, 4(3), 432–444.
- Badan Pusat Statistik (BPS). (2017). *Statistik Indonesia*. Jakarta: Badan Pusat Statistik (BPS).
- Barba, L., Rodríguez, N., dan Montt, C. (2014). Smoothing strategies combined with ARIMA and neural networks to improve the forecasting of traffic accidents. *The Scientific World Journal*, 2014.
- Biederman, P. S. (1993). The role of forecasting at trans world airlines. *The Journal of Business Forecasting*, 12(3), 3.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford University Press.
- Blinova, T. O. (2007). Analysis of possibility of using neural network to forecast passenger traffic flows in Russia. *Aviation*, 11(1), 28–34.
- Blunk, S. S., Clark, D. E., dan McGibany, J. M. (2006). Evaluating the long-run impacts of the 9/11 terrorist attacks on US domestic airline travel. *Applied economics*, 38(4), 363–370.
- Chen, C. F., Chang, Y. H., dan Chang, Y. W. (2009). Seasonal ARIMA forecasting of inbound air travel arrivals to Taiwan. *Transportmetrica*, 5(2), 125–140.
- Chen, K. Y. (2011). Combining linear and nonlinear model in forecasting tourism demand. *Expert Systems with Applications*, 38(8), 10368–10376.
- Chen, K. Y., dan Wang, C. H. (2007). A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. *Expert Systems with Applications*, 32(1), 254–264.
- Cortes, C., dan Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297.

- De Gooijer, J. G., dan Hyndman, R. J. (2006). 25 years of time series forecasting. *International journal of forecasting*, 22(3), 443–473.
- Díaz-Robles, L. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., dan Moncada-Herrera, J. A. (2008). A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile. *Atmospheric Environment*, 42(35), 8331–8340.
- Fairbanks, M. (2012). Lalu Lintas Bertumbuh, Kebutuhan Bertumbuh. *Jurnal Prakarsa Infrastruktur Indonesia*, Edisi 9 (Januari 2012), 4–8.
- Faraway, J., dan Chatfield, C. (1998). Time series forecasting with neural networks: a comparative study using the air line data. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 47(2), 231–250.
- Faruk, D. Ö. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 23(4), 586–594.
- Ghomi, S. F., dan Forghani, K. (2016). Airline passenger forecasting using neural networks and Box-Jenkins. In *Industrial Engineering (ICIE), 2016 12th International Conference on* (hal. 10–13). IEEE.
- Grosche, T., Rothlauf, F., dan Heinzl, A. (2007). Gravity models for airline passenger volume estimation. *Journal of Air Transport Management*, 13(4), 175–183.
- Haykin, S. (2009). *Neural Networks and Learning Machines Third Edition*. Upper Saddle River, New Jersey, USA: Pearson Education.
- Heng, H. J., Zheng, B. Z., dan Li, Y. J. (2009). Study of SVM-based air-cargo demand forecast model. In *Computational Intelligence and Security, 2009. CIS'09. International Conference on* (Vol. 2, hal. 53–55). IEEE.
- Hsu, C. W., Chang, C. C., dan Lin, C. J. (2003). A practical guide to support vector classification. Dipresentasikan pada Department of Computer Science and Information Engineering, National Taiwan University.

- Hyndman, R., Koehler, A. B., Ord, J. K., dan Snyder, R. D. (2008). *Forecasting with exponential smoothing: the state space approach*. Springer Science dan Business Media.
- Kementerian Perhubungan. (2016). *Statistik Perhubungan Buku 1*. Jakarta: Kementerian Perhubungan.
- Khashei, M., dan Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with applications*, 37(1), 479–489.
- Lai, S. L., dan Lu, W. L. (2005). Impact analysis of September 11 on air travel demand in the USA. *Journal of Air Transport Management*, 11(6), 455–458.
- Lee, M., Suhartono, dan Hamzah, N. (2010). Calendar variation model based on ARIMAX for forecasting sales data with Ramadhan effect. In *Proceedings of the Regional Conference on Statistical Sciences* (hal. 349–361).
- Lee, T. H., White, H., dan Granger, C. W. (1993). Testing for neglected nonlinearity in time series models: A comparison of neural network methods and alternative tests. *Journal of Econometrics*, 56(3), 269–290.
- Lim, C., dan McAleer, M. (1999). A seasonal analysis of Malaysian tourist arrivals to Australia. *Mathematics and computers in simulation*, 48(4), 573–583.
- Makridakis, S., dan Hibon, M. (1997). ARMA models and the Box–Jenkins methodology. *Journal of Forecasting*, 16, 147–163.
- Makridakis, S., dan Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16(4), 451–476.
- Matsumoto, H. (2004). International urban systems and air passenger and cargo flows: some calculations. *Journal of Air Transport Management*, 10(4), 239–247.
- Medeiros, M. C., McAleer, M., Slotje, D., Ramos, V., dan Rey-Maqueira, J. (2008). An alternative approach to estimating demand: Neural network regression with conditional volatility for high frequency air passenger arrivals. *Journal of Econometrics*, 147(2), 372–383.

- Ming, W., Bao, Y., Hu, Z., dan Xiong, T. (2014). Multistep-ahead air passengers traffic prediction with hybrid ARIMA-SVMs models. *The Scientific World Journal*, 2014.
- Moghadam, R. A., dan Keshmirpour, M. (2011). Hybrid ARIMA and neural network model for measurement estimation in energy-efficient wireless sensor networks. In *International Conference on Informatics Engineering and Information Science* (hal. 35–48). Springer.
- Pai, P. F., dan Lin, C. S. (2005). A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega*, 33(6), 497–505.
- PT Angkasa Pura I. (2016). *Membangun Kebanggaan Bangsa Melalui Percepatan Pembangunan Infrastruktur Bandara Laporan Tahunan 2016*. Jakarta: PT Angkasa Pura I (Persero).
- PT Angkasa Pura II. (2016). *Laporan Tahunan 2016*. Jakarta: PT Angkasa Pura II (Persero).
- Shabri, A. (2015). Least Square Support Vector Machines as an Alternative Method in Seasonal Time Series Forecasting. *Applied Mathematical Sciences*, 9(124), 6207–6216.
- Shabri, A., dan Suhartono. (2012). Streamflow forecasting using least-squares support vector machines. *Hydrological Sciences Journal*, 57(7), 1275–1293.
- Shahwan, T., dan Odening, M. (2007). Forecasting agricultural commodity prices using hybrid neural networks. *Computational Intelligence in Economics and Finance* (Eds: Shu-Heng Chen, Paul P. Wang and Tzu-Wen Kuo), Springer, Berlin, 63–74.
- Shumway, R. H., dan Stoffer, D. S. (2006). *Time series analysis and its applications: with R examples*. Springer Science dan Business Media.
- Smola, A. J., dan Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3), 199–222.

- Teräsvirta, T., Lin, C. F., dan Granger, C. W. (1993). Power of the neural network linearity test. *Journal of time series analysis*, 14(2), 209–220.
- Tsui, W. H. K., Balli, H. O., Gilbey, A., dan Gow, H. (2014). Forecasting of Hong Kong airport's passenger throughput. *Tourism Management*, 42, 62–76.
- Weatherford, L. R., Gentry, T. W., dan Wilamowski, B. (2003). Neural network forecasting for airlines: A comparative analysis. *Journal of Revenue and Pricing Management*, 1(4), 319–331.
- Wei, W. W. S. (2006). *Time series analysis: univariate and multivariate methods*. Pearson Addison Wesley.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
- Zhang, G., Patuwo, B. E., dan Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35–62.
- Zou, H. F., Xia, G. P., Yang, F. T., dan Wang, H. Y. (2007). An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting. *Neurocomputing*, 70(16), 2913–2923.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran 1. Syntak SAS Time Series Regression

```
data penumpang;

infile "D:\S2 PASCASARJANA ITS\Thesis\Olah Data\1. CGK_TSR\CGK_Xlsig.sas";

input Y1_1t t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1tmin1 V2tmin1 V3tmin1
V4tmin1 V1t V2t V3t V4t V1tpl1 V2tpl1 V3tpl1 V4tpl1 lag1 lag5 lag11 lag12 lag13;
datalines;

/*----- Variasi Kalender Bandara Soekarno Hatta -----*/
/*----- Data Jumlah Penumpang Domestik yang Berangkat -----*/
/*----- Dengan Deteksi Outlier dan Parameter yang Signifikan -----*/

data penumpang;
set penumpang;
if _n_=76 then A76=1; else A76=0;
if _n_=88 then A88=1; else A88=0;
if _n_=126 then A126=1; else A126=0;
if _n_=152 then A152=1; else A152=0;
if _n_=156 then A156=1; else A156=0;
if _n_=158 then A158=1; else A158=0;
if _n_=169 then A169=1; else A169=0;
if _n_=171 then A171=1; else A171=0;
if _n_=177 then A177=1; else A177=0;

proc arima data = penumpang;
    identify var=Y1_1t crosscorr=(t S1 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12
V1tmin1 V2tmin1 V3tmin1 V2t V4t V2tpl1 lag1 lag5 lag11 lag12 lag13 A76 A88 A126
A152 A156 A158 A169 A171 A177) nlag=24;
    run;
    estimate input=(t S1 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1tmin1 V2tmin1
V3tmin1 V2t V4t V2tpl1 lag1 lag5 lag12 lag13 A76 A88 A126 A152 A156 A158 A169
A171 A177) noconstant method=cls;
    forecast out = penumpang lead=12;
    run;

proc univariate data=penumpang normal;
    var residual;
    run;

proc export data=work.penumpang
    outfile='D:\CGK_TSR\lsig.xls'
    dbms=excel
    replace;
    run;
```

Lampiran 2. *Syntax SAS ARIMAX Variasi Kalender*

```
data penumpang;

infile "D:\S2 PASCASARJANA ITS\Thesis\Olah Data\1. CGK_TSR\CGK_Xlsig.sas";

input Y1_1t t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1tmin1 V2tmin1 V3tmin1
V4tmin1 V1t V2t V3t V4t V1tpl1 V2tpl1 V3tpl1 V4tpl1;
datalines;

/*----- Variasi Kalender Bandara Soekarno Hatta -----*/
/*----- Data Jumlah Penumpang Domestik yang Berangkat -----*/
/*----- Parameter yang Signifikan -----*/

data penumpang;
set penumpang;
if _n_=76 then A76=1; else A76=0;
if _n_=156 then A156=1; else A156=0;

proc arima data=work.penumpang;
    identify var=Y1_1t crosscorr=(t S1 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12
V1tmin1 V2t V4t A76 A156) nlag=24;
run;
    estimate p=(1,2,5)(12) input=(t S1 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12
V1tmin1 V2t V4t A76 A156) noconstant method=cls;
    forecast out=ramalan lead=28;
run;

proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
    outfile='D:\F_CGK_ARIMAX1sig.xls'
    dbms=excel
    replace;
run;
```

Lampiran 3. Syntak R Pengujian Nonlinieritas

```
> rm(list=ls(all=TRUE))
> graphics.off()

> library(readxl)
> library(tseries)
> Data<-read_excel("D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1. CGK_00000/2. Data
Non Linier.xlsx")

> #UJI NONLINIERITAS Y1_lt
> Y1_lt=as.ts(Data$Y1_lt)
> trend=as.ts(Data$t)
>
> Y1t=Y1_lt[14:200]
> Y1_lt.1=Y1_lt[13:199]          #data residual lag 1
> Y1_lt.5=Y1_lt[9:195]           #data residual lag 5
> Y1_lt.12=Y1_lt[2:188]          #data residual lag 12
> Y1_lt.13=Y1_lt[1:187]          #data residual lag 13
> t1=trend[14:200]
>
> X1t=data.frame(cbind(t1,Y1_lt.1,Y1_lt.5,Y1_lt.12,Y1_lt.13))
> terasvirta.test(X1t,Y1t)

      Teraesvirta Neural Network Test

data:  X1t and Y1t
X-squared = 104.8, df = 50, p-value = 9.31e-06

> #UJI NONLINIERITAS Y2_lt
> Y2_lt=as.ts(Data$Y2_lt)
> trend=as.ts(Data$t)
>
> Y2t=Y2_lt[13:200]
> Y2_lt.1=Y2_lt[12:199]          #data residual lag 1
> Y2_lt.2=Y2_lt[11:198]          #data residual lag 2
> Y2_lt.12=Y2_lt[1:188]          #data residual lag 12
> t2=trend[13:200]
>
> X2t=data.frame(cbind(t2,Y2_lt.1,Y2_lt.2,Y2_lt.12))
> terasvirta.test(X2t,Y2t)

      Teraesvirta Neural Network Test

data:  X2t and Y2t
X-squared = 45.947, df = 30, p-value = 0.03144
```

Lampiran 4. Syntak R *hybrid* TSR-NN

```
rm(list=ls(all=TRUE))
graphics.off()

library(readxl)
library(lmtest)
library(tseries)
library(forecast)
library(neuralnet)
library(nnetpredint)

#MEMBACA DATA#
TSRall<-read_excel("D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_TSR_NN/F_CGK_TSR_NN1.xls")
Yl_1t=as.ts(TSRall$X1)
fitsYl_1t=as.ts(TSRall$FORECAST)
Nt=Yl_1t-fitsYl_1t

Ntrain=as.ts(Nt[14:188])          #menentukan data training
Ntest=as.ts(Nt[189:200])         #menentukan data testing

#MEMBUAT PLOT TIME SERIES#
par(mar=c(3.1,3.2,1,0.3),mgp=c(2.1,0.5,0))
plot(Nt,axes=F,ylab="Departure Domestic Passenger", xlab="Tahun")
box()
axis(side=2,lwd=0.5,cex.axis=0.7,las=2,cex=0.5)
axis(side=1,at=seq(1,200,12),label=c(2001:2017),lwd=0.5,cex.axis=0.8,las=0)
points(Nt,col="red3",cex=0.75,pch=19)

#PREPROCESSING STANDARDIZED#
mean.Ntrain=mean(Ntrain)
sd.Ntrain=sd(Ntrain)
Ntrain_std<-scale(Ntrain)

#PEMODELAN NN#
at=Ntrain_std[14:175]            #mendefinisikan data untuk data training
at1=Ntrain_std[13:174]           #data residual lag 1
at5=Ntrain_std[9:170]            #data residual lag 2
at12=Ntrain_std[2:163]           #data residual lag 3
at13=Ntrain_std[1:162]           #data residual lag 11

data=data.frame(cbind(at,at1,at5,at12,at13))
set.seed(8)
h=10
model.NN=neuralnet(at~at1+at5+at12+at13,data=data,hidden=h,act.fct="logistic",li
near.output=TRUE,likelihood=TRUE)
fits.NN=(as.ts(unlist(model.NN$net.result)))*sd.Ntrain+mean.Ntrain #data
ramalan Nt untuk training
fits.TSR_NN=fitsYl_1t[27:188]+fits.NN #data ramalan Yt untuk training
par(mfrow=c(1,1),mar=c(2.8,3,1.2,0.4))
plot(model.NN)

#PREDIKSI K-STEP AHEAD
k=12
Ntest=c(at,rep(0,k))
for(i in (length(at)+1):(length(at)+k))
{
  Xtest=t(matrix(c(Ntest[i-1],Ntest[i-5],Ntest[i-12],Ntest[i-13]),byrow=FALSE))
  Ntest[i]=compute(model.NN,covariate=Xtest)$net.result
}
fore.NN=Ntest[(length(at)+1):(length(at)+k)]*sd.Ntrain+mean.Ntrain
fore.TSR_NN=fitsYl_1t[189:200]+fore.NN
#data ramalan Yt untuk testing

#PERHITUNGAN KRITERIA RMSE, MAE, DAN MAPE
akurasi=matrix(0,3,2)
colnames(akurasi)=c("Training","Testing")
rownames(akurasi)=c("RMSE","MAE","MAPE")

Yl_1ttrain=Yl_1t[27:188]
```



```

Y1_lttest=Y1_lt[189:200]
akurasi[1,1]=accuracy(fits.TSR_NN,Y1_lttrain)[1,2]
akurasi[2,1]=accuracy(fits.TSR_NN,Y1_lttrain)[1,3]
akurasi[3,1]=accuracy(fits.TSR_NN,Y1_lttrain)[1,5]
akurasi[1,2]=accuracy(as.vector(fore.TSR_NN),Y1_lttest)[1,2]
akurasi[2,2]=accuracy(as.vector(fore.TSR_NN),Y1_lttest)[1,3]
akurasi[3,2]=accuracy(as.vector(fore.TSR_NN),Y1_lttest)[1,5]
akurasi

#PLOT PERBANDINGAN DATA AKTUAL DAN RAMALAN
a=min(min(fits.TSR_NN),min(Y1_lttrain))      #batas bawah plot data training
b=max(max(fits.TSR_NN),max(Y1_lttrain))      #batas atas plot data training
c=min(min(fore.TSR_NN),min(Y1_lttest))      #batas bawah plot data testing
d=max(max(fore.TSR_NN),max(Y1_lttest))      #batas atas plot data testing

par(mfrow=c(2,1),mar=c(2.3,2.7,1.2,0.4))    #banyaknya gambar dan ukuran margin
par(mgp=c(1.3,0.5,0))                      #jarak judul label ke axis

#PLOT DATA TRAINING#
plot(as.ts(Y1_lttrain),ylab="Xt",xlab="t",lwd=2,axes=F,ylim=c(a*1.1,b*1.1))
box()
title("Data training",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=seq(1,164,12))
lines(as.ts(fits.TSR_NN),col="purple2",lwd=2)

#PLOT DATA TESTING#
Plot(as.ts(Y1_lttest),ylab="Xt",xlab="t",lwd=2,ylim=c(c*0.5,d*1.2),cex.lab=0.8,
,axes=F)
box()
title("Data testing",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=c(1:12),labels=c(1:12))
lines(as.vector(fore.TSR_NN),col="red",lwd=2)

#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
col=c("black","red"),lwd=2,cex=0.7)

#MENYIMPAN HASIL PREDIKSI KEDALAM NOTEPAD
yltTSR_NN=c(fits.TSR_NN,fore.TSR_NN)
write.table(Y1_ltTSR_NN,"D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_TSR_NN/Y1_ltfits_TSR_NN.txt",dec="," ,sep="\t",col.names=FALSE)

```

Lampiran 5. Syntak R hybrid ARIMAX-NN

```
rm(list=ls(all=TRUE))
graphics.off()

library(readxl)
library(lmtest)
library(tseries)
library(forecast)
library(neuralnet)
library(nnetpredint)

#MEMBACA DATA#
ARIMAXall<-read_excel("D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_ARIMAX_NN/F_CGK_ARIMAX_NN1.xls")
Y1_lt=as.ts(ARIMAXall$Y1_lt)
fitsY1_lt=as.ts(ARIMAXall$FORECAST[1:200])
Nt=Y1_lt-fitsY1_lt #menghitung
nilai_residual (Nt)

Ntrain=as.ts(Nt[1:188]) #menentukan data training
Ntest=as.ts(Nt[189:200]) #menentukan data testing

#MEMBUAT PLOT TIME SERIES#
par(mar=c(3.1,3.2,1,0.3),mgp=c(2.1,0.5,0))
plot(Nt,axes=F,ylab="Departure Domestic Passenger", xlab="Tahun")
box()
axis(side=2,lwd=0.5,cex.axis=0.7,las=2,cex=0.5)
axis(side=1,at=seq(1,200,12),label=c(2001:2017),lwd=0.5,cex.axis=0.8,las=0)
points(Nt,col="red3",cex=0.75,pch=19)

#PREPROCESSING STANDARDIZED#
mean.Ntrain=mean(Ntrain)
sd.Ntrain=sd(Ntrain)
Ntrain_std<-scale(Ntrain)

#PEMODELAN NN#
at=Ntrain_std[13:188] #mendefinisikan data untuk data training
at1=Ntrain_std[12:187] #data residual lag 1
at2=Ntrain_std[11:186] #data residual lag 5
at5=Ntrain_std[8:183] #data residual lag 5
at12=Ntrain_std[1:176] #data residual lag 12

data=data.frame(cbind(at,at1,at2,at5,at12))
set.seed(3)
h=9
model.NN=neuralnet(at~at1+at2+at5+at12,data=data,hidden=h,act.fct="logistic",lin
ear.output=TRUE,likelihood=TRUE)
fits.NN=(as.ts(unlist(model.NN$net.result)))*sd.Ntrain+mean.Ntrain #data
ramalan Nt untuk training
fits.ARIMAX_NN=fitsY1_lt[13:188]+fits.NN #data ramalan Yt untuk training
par(mfrow=c(1,1),mar=c(2.8,3,1.2,0.4))
plot(model.NN)

#PREDIKSI K-STEP AHEAD
k=12
Ntest=c(at,rep(0,k))
for(i in (length(at)+1):(length(at)+k))
{
  Xtest=t(matrix(c(Ntest[i-1],Ntest[i-2],Ntest[i-5],Ntest[i-12]),byrow=FALSE))
  Ntest[i]=compute(model.NN,covariate=Xtest)$net.result
}
fore.NN=Ntest[(length(at)+1):(length(at)+k)]*sd.Ntrain+mean.Ntrain
fore.ARIMAX_NN=fitsY1_lt[189:200]+fore.NN
#data ramalan Yt untuk testing

#PERHITUNGAN KRITERIA RMSE, MAE, DAN MAPE
akurasi=matrix(0,3,2)
colnames(akurasi)=c("Training","Testing")
rownames(akurasi)=c("RMSE","MAE","MAPE")
```

```

Y1_lttrain=Y1_lt[13:188]
Y1_lttest=Y1_lt[189:200]
akurasi[1,1]=accuracy(fits.ARIMAX_NN,Y1_lttrain)[1,2]
akurasi[2,1]=accuracy(fits.ARIMAX_NN,Y1_lttrain)[1,3]
akurasi[3,1]=accuracy(fits.ARIMAX_NN,Y1_lttrain)[1,5]
akurasi[1,2]=accuracy(as.vector(fore.ARIMAX_NN),Y1_lttest)[1,2]
akurasi[2,2]=accuracy(as.vector(fore.ARIMAX_NN),Y1_lttest)[1,3]
akurasi[3,2]=accuracy(as.vector(fore.ARIMAX_NN),Y1_lttest)[1,5]
akurasi

#PLOT PERBANDINGAN DATA AKTUAL DAN RAMALAN
a=min(min(fits.ARIMAX_NN),min(Y1_lttrain))      #batas bawah plot data training
b=max(max(fits.ARIMAX_NN),max(Y1_lttrain))      #batas atas plot data training
c=min(min(fore.ARIMAX_NN),min(Y1_lttest))      #batas bawah plot data testing
d=max(max(fore.ARIMAX_NN),max(Y1_lttest))      #batas atas plot data testing

par(mfrow=c(2,1),mar=c(2.3,2.7,1.2,0.4))      #banyaknya gambar dan ukuran margin
par(mgp=c(1.3,0.5,0))                        #jarak judul label ke axis

#PLOT DATA TRAINING#
plot(as.ts(Y1_lttrain),ylab="Y1_lt",xlab="t",lwd=2,axes=F,ylim=c(a*1.1,b*1.1))
box()
title("Data training",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=seq(1,169,12))
lines(as.ts(fits.ARIMAX_NN),col="purple2",lwd=2)

#PLOT DATA TESTING#
plot(as.ts(Y1_lttest),ylab="Y1_lt",xlab="t",lwd=2,ylim=c(c*0.5,d*1.2),cex.lab=
0.8,axes=F)
box()
title("Data testing",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=c(1:12),labels=c(1:12))
lines(as.vector(fore.ARIMAX_NN),col="red",lwd=2)

#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
col=c("black","red"),lwd=2,cex=0.7)

#MENYIMPAN HASIL PREDIKSI KEDALAM NOTEPAD
Y1_ltARIMAX_NN=c(fits.ARIMAX_NN,fore.ARIMAX_NN)
write.table(Y1_ltARIMAX_NN,"D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_ARIMAX_NN/Y1_ltfits_ARIMAX_NN.txt",dec=".",sep="\t",col.names=FALSE)

```

Lampiran 6. Syntak R hybrid TSR-SVR

```
rm(list=ls(all=TRUE))
graphics.off()

library(readxl)
library(kernlab)

#DATA ALL#
TSRall<-read_excel("D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_TSR_SVR/F_CGK_TSR_SVR1.xls")
Y1_lt=as.ts(TSRall$X1)
fitsY1_lt=as.ts(TSRall$FORECAST)
Nt=Y1_lt-fitsY1_lt

y.at=as.ts(Nt[14:200])                                #menghitung
nilai residual (Nt)
at=y.at[14:187]
at1=y.at[13:186]          #data residual lag 1
at5=y.at[9:182]           #data residual lag 5
at12=y.at[2:175]          #data residual lag 12
at13=y.at[1:174]          #data residual lag 13

data=data.frame(cbind(at,at1,at5,at12,at13))
x.at=data[,2:5]

#data training
atrain=as.ts(at[1:162])
xtrain=x.at[1:162,]

#data testing
atest=as.ts(at[163:174])
xtest=x.at[163:174,]

Y1_lttrain=Y1_lt[27:188]
Y1_ltttest=Y1_lt[189:200]

#Metode Grid Search Parameter Optimum
eps      = seq(100,1000, by=50)
C         = seq(1000,100000, by=2000)
sigma     = seq((0.05),(0.1), by=0.01)
nn        = length(eps)*length(C)*length(sigma)
err       = array(0, nn)
mape.train= array(0,nn)
mape.test  = array(0,nn)
tab        = matrix(0,nn,6)

s=1
for(i in 1:length(eps))      {
for(j in 1:length(C))        {
for(k in 1:length(sigma)){
  model.svr =
ksvm(at~at1+at5+at12+at13,data=data,scaled=F,epsilon=eps[i],kpar=list(sigma=sigma[k]),C=C[j])
err[s]=error(model.svr)

fits.SVR      =predict(model.svr,xtrain)
fits.TSR_SVR  =fitsY1_lt[27:188]+fits.SVR
mape.train[s] =mean(abs((fits.TSR_SVR-Y1_lttrain)/Y1_lttrain)*100)

m=12
for(l in (length(at)-m):(length(at)-1))
Atest=c(at,rep(0,m))
{
  Xtest=t(matrix(c(Atest[l-1],Atest[l-5],Atest[l-12],Atest[l-13]),byrow=FALSE))
  Atest[l]=predict(model.svr,Xtest)
}
fore.SVR=Atest[(length(at)-m):(length(at)-1)]
fore.TSR_SVR=fitsY1_lt[189:200]+fore.SVR
mape.test[s] = mean(abs((fore.TSR_SVR-Y1_ltttest)/Y1_ltttest)*100)
s=s+1
```

```

}
}
}
s=1
for(i in 1:length(eps)){
  for(j in 1:length(C)){
    for(k in 1:length(sigma)){
      tab[s,1]=eps[i]
      tab[s,2]=C[j]
      tab[s,3]=sigma[k]
      tab[s,4]=err[s]
      tab[s,5]=mape.train[s]
      tab[s,6]=mape.test[s]
      s=s+1
    }
  }
}
colnames(tab)=c("epsilon","cost","sigma","error","MAPE","MAPEp")
write.csv(tab,file="CGK_TSR_SVR1.csv")

sorttabel=tab[order(mape.test),]
head(sorttabel)
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]

#Mendapatkan Model Optimal
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]
model.optimal    =
ksvm(at~at1+at5+at12+at13,data=data,scaled=F,epsilon=eps.optimal,kpar=list(sigma
=sigma.optimal), C=C.optimal)
bias=b(model.optimal)
alpha.idx=alphaindex(model.optimal)
alphas=alpha(model.optimal)

#Prediksi data untuk data in-sample dan out-sample
fits.SVR = predict(model.optimal,xtrain)
fits.TSR_SVR = fitsY1_lt[27:188]+fits.SVR
mape.train = mean(abs((fits.TSR_SVR-Y1_lttrain)/Y1_lttrain)*100)

#PREDIKSI K-STEP AHEAD
m=12
for(l in (length(at)-m):(length(at)-1))
Atest=c(at,rep(0,k))
{
  Xtest=t(matrix(c(Atest[l-1],Atest[l-5],Atest[l-12],Atest[l-13]),byrow=FALSE))
  Atest[l]=predict(model.optimal,Xtest)
}
fore.SVR=Atest[(length(at)-m):(length(at)-1)]
fore.TSR_SVR=fitsY1_lt[189:200]+fore.SVR
mape.test = mean(abs((fore.TSR_SVR-Y1_ltttest)/Y1_ltttest)*100)

#PREDIKSI OUTSAMPLE
fore.SVR1 = predict(model.optimal,xtest)
fore.TSR_SVR1 = fitsY1_lt[189:200]+fore.SVR1
mape.test1 = mean(abs((fore.TSR_SVR1-Y1_ltttest)/Y1_ltttest)*100)

akurasi=cbind(mape.train,mape.test)
colnames(akurasi)=c("Training","Testing")
rownames(akurasi)=c("MAPE")
akurasi

#PLOT PERBANDINGAN DATA AKTUAL DAN RAMALAN
a=min(min(fits.TSR_SVR),min(Y1_lttrain))      #batas bawah plot data training
b=max(max(fits.TSR_SVR),max(Y1_lttrain))      #batas atas plot data training
c=min(min(fore.TSR_SVR),min(Y1_ltttest))      #batas bawah plot data testing
d=max(max(fore.TSR_SVR),max(Y1_ltttest))      #batas atas plot data testing

par(mfrow=c(2,1),mar=c(2.3,2.7,1.2,0.4))    #banyaknya gambar dan ukuran margin
par(mgp=c(1.3,0.5,0))                        #jarak judul label ke axis

```

```

#PLOT DATA TRAINING#
plot(as.ts(Y1_1ttrain),ylab="Y1_1t",xlab="t",lwd=2,axes=F,ylim=c(a*1.1,b*1.1))
box()
title("Data training",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=seq(1,164,6))
lines(as.ts(fits.TSR_SVR),col="purple2",lwd=2)
#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
      col=c("black","purple2"),lwd=2,cex=0.7)

#PLOT DATA TESTING#
Plot(as.ts(Y1_1ttest),ylab="Y1_1t",xlab="t",lwd=2,ylim=c(c*0.5,d*1.2),cex.lab
=0.8,axes=F)
box()
title("Data testing",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=c(1:12),labels=c(1:12))
lines(as.vector(fore.TSR_SVR),col="red",lwd=2)

#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
      col=c("black","red"),lwd=2,cex=0.7)

#MENYIMPAN HASIL PREDIKSI KEDALAM NOTEPAD
Y1_1tTSR_SVR=c(fits.TSR_SVR,fore.TSR_SVR)
write.table(Y1_1tTSR_SVR,"D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_TSR_SVR/Y1_1tfits_TSR_SVR.txt",dec="," ,sep="\t",col.names=FALSE)

```

Lampiran 7. Syntak R hybrid ARIMAX-SVR

```
rm(list=ls(all=TRUE))
graphics.off()

library(readxl)
library(kernlab)

#DATA ALL#
ARIMAXall<-read_excel("D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_ARIMAX_SVR/F_CGK_ARIMAX_SVR1.xls")
Yl_1t=as.ts(ARIMAXall$Yl_1t)
fitsYl_1t=as.ts(ARIMAXall$FORECAST[1:200])
Nt=Yl_1t-fitsYl_1t

y.at=as.ts(Nt[1:200])
at=y.at[13:200]
at1=y.at[12:199]      #data residual lag 1
at2=y.at[11:198]      #data residual lag 2
at5=y.at[8:195]        #data residual lag 5
at12=y.at[1:188]       #data residual lag 12

data=data.frame(cbind(at,at1,at2,at5,at12))
x.at=data[,2:5]

#data training
atrain=as.ts(at[1:176])
xtrain=x.at[1:176,]

#data testing
atest=as.ts(at[177:188])
xtest=x.at[177:188,]

Yl_1ttrain=Yl_1t[13:188]
Yl_1ttest=Yl_1t[189:200]

#Metode Grid Search Parameter Optimum
eps      = seq(100,1000, by=50)
C        = seq(1000,100000, by=2000)
sigma    = seq((0.05),(0.1), by=0.01)
nn       = length(eps)*length(C)*length(sigma)
err       = array(0, nn)
mape.train = array(0,nn)
mape.test  = array(0,nn)
tab        = matrix(0,nn,6)

s=1
for(i in 1:length(eps)) {
  for(j in 1:length(C)) {
    for(k in 1:length(sigma)){
      model.svr =
ksvm(at~at1+at2+at5+at12,data=data,scaled=F,epsilon=eps[i],kpar=list(sigma=sigma
[k]),C=C[j])
      err[s]=error(model.svr)
      fits.SVR      =predict(model.svr,xtrain)
      fits.ARIMAX_SVR =fitsYl_1t[13:188]+fits.SVR
      mape.train[s] =mean(abs((fits.ARIMAX_SVR-Yl_1ttrain)/Yl_1ttrain)*100)

      m=12
      for(l in (length(at)-m):(length(at)-1))
      Atest=c(at,rep(0,m))
      {
        Xtest=t(matrix(c(Atest[l-1],Atest[l-2],Atest[l-5],Atest[l-12]),byrow=FALSE))
        Atest[l]=predict(model.svr,Xtest)
      }
      fore.SVR=Atest[(length(at)-m):(length(at)-1)]
      fore.ARIMAX_SVR =fitsYl_1t[189:200]+fore.SVR
      mape.test[s] =mean(abs((fore.ARIMAX_SVR-Yl_1ttest)/Yl_1ttest)*100)
      s=s+1
    }
  }
}
```

```

}
s=1
for(i in 1:length(eps)){
  for(j in 1:length(C)){
    for(k in 1:length(sigma)){
      tab[s,1]=eps[i]
      tab[s,2]=C[j]
      tab[s,3]=sigma[k]
      tab[s,4]=err[s]
      tab[s,5]=mape.train[s]
      tab[s,6]=mape.test[s]
      s=s+1
    }
  }
}
colnames(tab)=c("epsilon","cost","sigma","error","MAPE","MAPEp")
write.csv(tab,file="CGK_ARIMAX_SVR1.csv")

sorttabel=tab[order(mape.test),]
head(sorttabel)
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]

#Mendapatkan Model Optimal
eps.optimal      = sorttabel[1,1]
C.optimal        = sorttabel[1,2]
sigma.optimal    = sorttabel[1,3]
model.optimal    =
ksvm(at~at1+at2+at5+at12,data=data,scaled=F,epsilon=eps.optimal,kpar=list(sigma=
sigma.optimal), C=C.optimal)
bias=b(model.optimal)
alpha.idx=alphaindex(model.optimal)
alphas=alpha(model.optimal)

#Prediksi data untuk data in-sample dan out-sample
fits.SVR = predict(model.optimal,xtrain)
fits.ARIMAX_SVR = fitsY1_lt[13:188]+fits.SVR
mape.train = mean(abs((fits.ARIMAX_SVR-Y1_lttrain)/Y1_lttrain)*100)

#PREDIKSI K-STEP AHEAD
m=12
for(l in (length(at)-m):(length(at)-1))
  Atest=c(at,rep(0,m))
  {
    Xtest=t(matrix(c(Atest[l-1],Atest[l-2],Atest[l-5],Atest[l-12]),byrow=FALSE))
    Atest[l]=predict(model.optimal,Xtest)
  }
fore.SVR=Atest[(length(at)-m):(length(at)-1)]
fore.ARIMAX_SVR=fitsY1_lt[189:200]+fore.SVR
mape.test = mean(abs((fore.ARIMAX_SVR-Y1_ltttest)/Y1_ltttest)*100)

fore.SVR1 = predict(model.optimal,xtest)
fore.ARIMAX_SVR1 = fitsY1_lt[189:200]+fore.SVR1
mape.test1 = mean(abs((fore.ARIMAX_SVR1-Y1_ltttest)/Y1_ltttest)*100)

akurasi=cbind(mape.train,mape.test)
colnames(akurasi)=c("Training","Testing")
rownames(akurasi)=c("MAPE")
akurasi

#PLOT PERBANDINGAN DATA AKTUAL DAN RAMALAN
a=min(min(fits.ARIMAX_SVR),min(Y1_lttrain))
b=max(max(fits.ARIMAX_SVR),max(Y1_lttrain))
c=min(min(fore.ARIMAX_SVR),min(Y1_ltttest))
d=max(max(fore.ARIMAX_SVR),max(Y1_ltttest))

par(mfrow=c(2,1),mar=c(2.3,2.7,1.2,0.4)) #banyaknya gambar dan ukuran margin
par(mgp=c(1.3,0.5,0)) #jarak judul label ke axis

#PLOT DATA TRAINING#
plot(as.ts(Y1_lttrain),ylab="Y1_lt",xlab="t",lwd=2,axes=F,ylim=c(a*1.1,b*1.1))

```



```

box()
title("Data training",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=seq(1,164,6))
lines(as.ts(fits.ARIMAX_SVR),col="purple2",lwd=2)
#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
      col=c("black","purple2"),lwd=2,cex=0.7)

#PLOT DATA TESTING#

plot(as.ts(Yl_1ttest),ylab="Yl_1t",xlab="t",lwd=2,ylim=c(c*0.5,d*1.2),cex.lab=0.8,axes=F)
box()
title("Data testing",line=0.3,cex.main=0.9)
axis(side=2,lwd=0.5,cex.axis=0.8,las=0)
axis(side=1,lwd=0.5,cex.axis=0.8,las=0,at=c(1:12),labels=c(1:12))
lines(as.vector(fore.ARIMAX_SVR),col="red",lwd=2)

#MEMBERI NAMA LEGEND#
legend("topleft",c("Data aktual","Data ramalan"),
      col=c("black","red"),lwd=2,cex=0.7)

#MENYIMPAN HASIL PREDIKSI KEDALAM NOTEPAD
Yl_1tARIMAX_SVR=c(fits.ARIMAX_SVR,fore.ARIMAX_SVR)
write.table(Yl_1tARIMAX_SVR,"D:/S2 PASCASARJANA ITS/Thesis/Olah Data/1.
CGK_ARIMAX_SVR/Yl_1tfits_ARIMAX_SVR.txt",dec="," ,sep="\t",col.names=FALSE)

```

Lampiran 8. Hasil Uji Asumsi Model TSR dan ARIMAX


A. Bandara Soekarno Hatta

- Penumpang Domestik yang Berangkat

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>Chi Sq
76	Additive	255619.6	17.39	<.0001
88	Additive	-205573	12.31	0.0005
126	Additive	217261.3	13.24	0.0003
152	Additive	191091.6	11.1	0.0009
156	Additive	233006.6	14.79	0.0001
158	Additive	-250231	17.05	<.0001
169	Additive	-250994	17.11	<.0001
171	Additive	-159618	7.85	0.0051
177	Additive	-201348	12.28	0.0005

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.989199	Pr < W 0.2046
Kolmogorov-Smirnov	D	0.060572	Pr > D 0.1164
Cramer-von Mises	W-Sq	0.115239	Pr > W-Sq 0.0737
Anderson-Darling	A-Sq	0.688102	Pr > A-Sq 0.0752



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.55	6	0.2733	-0.158	0.059	0.058	0.074	-0.046	0.050
12	10.55	12	0.5678	0.095	-0.040	-0.029	-0.029	0.059	0.021
18	17.39	18	0.4963	-0.079	0.136	0.080	-0.021	0.062	-0.001
24	31.73	24	0.1338	0.146	-0.101	0.137	-0.016	-0.003	-0.143
30	36.78	30	0.1835	0.041	0.073	-0.103	0.006	-0.079	-0.014

- Penumpang Domestik yang Datang

Model TSR


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>Chi Sq
76	Additive	297771	10.8	0.001
128	Additive	-324172.2	12.25	0.0005
129	Additive	342219.9	13.52	0.0002
157	Additive	-362090.1	13.96	0.0002
158	Additive	-393650.5	16.58	<.0001
160	Additive	-251869.1	7.8	0.0052
163	Additive	-368036.5	15.43	<.0001
169	Additive	-228748.9	6.63	0.0101
170	Additive	-222617.5	6.4	0.0114
177	Additive	-431346.3	19.28	<.0001

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.993792	Pr < W 0.6661
Kolmogorov-Smirnov	D	0.042314	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.043136	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq	0.304841	Pr > A-Sq >0.2500

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
76	Additive	255619.6	17.39	<.0001
156	Additive	233006.6	14.79	0.0001

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.977228	Pr < W 0.0037
Kolmogorov-Smirnov	D	0.053343	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.128114	Pr > W-Sq 0.0472
Anderson-Darling	A-Sq	0.777673	Pr > A-Sq 0.0440





Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	0.29	2	0.8662	-0.012	-0.028	0.010	-0.014	-0.010	-0.012
12	11.86	8	0.1573	0.089	0.002	0.070	-0.190	0.094	0.003
18	18.96	14	0.1665	-0.129	0.092	0.085	0.007	-0.037	-0.029
24	23.15	20	0.2816	0.113	0.008	0.022	-0.031	0.046	0.056
30	30.17	26	0.2608	-0.060	0.148	-0.068	-0.001	-0.002	0.041
36	43.39	32	0.0862	-0.085	-0.035	0.016	-0.056	0.101	-0.186

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
76	Additive	297771	10.8	0.001
160	Additive	-251869.1	7.8	0.0052

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.981523	Pr < W 0.0138
Kolmogorov-Smirnov	D	0.055064	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.080971	Pr > W-Sq 0.2077
Anderson-Darling	A-Sq	0.639964	Pr > A-Sq 0.0952






Autocorrelation Check of Residuals											
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations							
6	1.71	3	0.6358	-0.020	-0.068	0.033	-0.021	0.011	-0.046		
12	4.02	9	0.9099	0.072	-0.013	0.053	-0.032	-0.013	0.047		
18	10.53	15	0.7853	0.040	0.117	-0.099	0.014	0.072	0.034		
24	18.53	21	0.6153	0.064	-0.038	0.127	-0.028	0.051	-0.110		
30	33.69	27	0.1753	-0.114	0.144	-0.010	-0.035	-0.182	0.018		
36	45.72	33	0.0695	0.053	-0.108	0.000	-0.062	0.174	-0.054		

- Penumpang Internasional yang Berangkat

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
37	Additive	67657.9	8.93	0.0028
96	Additive	-80720	12.07	0.0005
126	Additive	71610.1	9.87	0.0017
147	Additive	62149.5	8.06	0.0045
151	Additive	-50425	7.29	0.0069

Tests for Normality				
Test		Statistic	p Value	
Shapiro-Wilk	W	0.989808	Pr < W	0.2406
Kolmogorov-Smirnov	D	0.055437	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.091435	Pr > W-Sq	0.1473
Anderson-Darling	A-Sq	0.553185	Pr > A-Sq	0.1560




Autocorrelation Check of Residuals											
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations							
6	8.07	6	0.2329	0.132	0.116	-0.005	0.082	-0.018	-0.082		
12	14.85	12	0.2498	0.042	-0.002	0.076	0.061	0.122	0.099		
18	19.02	18	0.3908	0.049	-0.029	-0.012	-0.097	0.005	-0.092		
24	35.18	24	0.0657	0.051	0.057	0.069	0.050	0.118	0.227		
30	37.87	30	0.1532	-0.041	-0.007	-0.035	-0.042	-0.087	-0.021		

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
28	Additive	-34651.5	7.31	0.0069
60	Additive	44323	11.57	0.0007
130	Additive	-60041.2	15.84	<.0001
142	Additive	30007.5	5.52	0.0188
152	Additive	60618.3	18.53	<.0001
176	Additive	56171	12.46	0.0004
160	Additive	-57975.2	15.04	0.0001

Tests for Normality				
Test		Statistic	p Value	
Shapiro-Wilk	W	0.982721	Pr < W	0.0203
Kolmogorov-Smirnov	D	0.058558	Pr > D	0.1148
Cramer-von Mises	W-Sq	0.163078	Pr > W-Sq	0.0172
Anderson-Darling	A-Sq	0.977977	Pr > A-Sq	0.0149



Autocorrelation Check of Residuals											
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations							
6	5.29	4	0.2591	-0.064	-0.034	0.147	0.016	-0.021	0.005		
12	13.62	10	0.1911	0.114	-0.072	0.121	-0.044	-0.027	0.079		
18	19.46	16	0.2457	0.015	-0.023	0.017	0.078	-0.140	-0.037		
24	30.14	22	0.1150	0.129	0.090	0.023	-0.025	0.151	-0.038		
30	32.72	28	0.2464	-0.088	0.010	-0.044	-0.028	0.006	-0.034		
36	36.53	34	0.3520	0.040	-0.043	0.097	0.026	0.045	0.030		

- Penumpang Internasional yang Datang


Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
108	Additive	85912.5	11.6	0.0007
158	Additive	-60216.7	9.1	0.0026
164	Additive	-80267	10.49	0.0012

Model ARIMAX


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
24	Additive	-161815	62.67	<.0001
61	Additive	-76275.8	14.51	0.0001

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.938033	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.065028	Pr > D	0.0689
Cramer-von Mises	W-Sq	0.223715	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.325613	Pr > A-Sq	<0.0050



Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations						
6	4.35	6	0.6296	-0.058	0.035	-0.037	0.038	0.114	-0.057	
12	10.77	12	0.5486	0.114	-0.016	0.063	-0.056	-0.003	0.117	
18	16.72	18	0.5422	-0.129	0.039	-0.054	0.084	-0.048	-0.014	
24	29.43	24	0.2043	0.075	-0.112	0.098	-0.112	0.145	0.034	
30	32.97	30	0.3240	-0.070	0.049	-0.067	0.034	-0.060	0.010	

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.994314	Pr < W	0.6918
Kolmogorov-Smirnov	D	0.039475	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.041	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.318159	Pr > A-Sq	>0.2500




Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations						
6	4.47	1	0.0345	-0.038	0.129	0.030	-0.034	0.056	0.008	
12	8.37	7	0.3011	0.058	-0.006	0.093	-0.069	-0.021	-0.048	
18	21.47	13	0.0642	-0.153	0.084	-0.062	0.129	-0.069	0.087	
24	24.89	19	0.1643	0.090	-0.025	0.057	-0.057	-0.024	0.018	
30	35.59	25	0.0780	-0.121	0.109	-0.098	0.049	-0.096	-0.012	
36	40.89	31	0.1101	-0.052	0.029	0.048	-0.041	0.099	-0.074	

- Kargo Domestik yang Dimuat

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
48	Additive	-2241.6	8.81	0.003
107	Additive	-4643.9	31.11	<.0001
124	Additive	4504.8	30.05	<.0001
131	Additive	3917.8	25.03	<.0001
134	Additive	-2504.4	10.04	0.0015
151	Additive	2081.1	7.67	0.0056
152	Additive	-2514.8	9.91	0.0016

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.982456	Pr < W 0.0202
Kolmogorov-Smirnov	D	0.054534	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.109074	Pr > W-Sq 0.0878
Anderson-Darling	A-Sq	0.606664	Pr > A-Sq 0.1156




Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations						
6	1.32	6	0.9705	0.017	0.009	0.032	0.033	0.003	0.066	
12	4.20	12	0.9795	0.023	-0.060	-0.013	-0.014	0.088	0.048	
18	8.55	18	0.9692	0.063	0.064	-0.019	0.092	0.015	0.065	
24	21.53	24	0.6073	-0.182	-0.105	-0.065	-0.045	0.107	0.009	
30	31.81	30	0.3762	0.100	-0.041	-0.064	-0.089	0.147	-0.036	
36	35.84	36	0.4760	-0.107	-0.038	-0.011	-0.044	-0.030	-0.044	

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
79	Additive	-2959.4	18.71	<.0001
107	Additive	-4003.2	28.08	<.0001
124	Additive	4089.8	28.63	<.0001
131	Additive	3809.5	27.36	<.0001
151	Additive	2572.3	15.49	<.0001

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.989781	Pr < W 0.1994
Kolmogorov-Smirnov	D	0.042855	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.079395	Pr > W-Sq 0.2170
Anderson-Darling	A-Sq	0.519408	Pr > A-Sq 0.1934




Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations						
6	7.19	4	0.1260	-0.074	0.093	-0.067	-0.016	0.076	0.112	
12	9.79	10	0.4594	0.024	-0.043	-0.035	-0.044	0.085	0.015	
18	18.83	16	0.2778	0.107	-0.074	0.028	0.041	0.100	0.119	
24	26.40	22	0.2348	-0.117	-0.082	-0.032	-0.021	0.063	0.099	
30	36.62	28	0.1275	0.005	-0.067	-0.045	-0.124	0.153	0.017	
36	41.01	34	0.1901	-0.076	0.002	-0.083	0.022	-0.051	0.068	

- Kargo Domestik yang Dibongkar

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
72	Additive	3783.9	51.32	<.0001
73	Additive	-1733	13.31	0.0003
79	Additive	1703.8	13.3	0.0003
135	Additive	-2813.8	30.13	<.0001
136	Additive	2889.7	31.32	<.0001
147	Additive	2188.2	18.43	<.0001

Tests for Normality		
Test	Statistic	p Value
Shapiro-Wilk	W	0.977488 Pr < W 0.0052
Kolmogorov-Smirnov	D	0.061723 Pr > D 0.0918
Cramer-von Mises	W-Sq	0.175269 Pr > W-Sq 0.1111
Anderson-Darling	A-Sq	1.143837 Pr > A-Sq 0.0054




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.78	6	0.5725	0.033	-0.069	0.013	-0.009	0.112	0.083
12	11.92	12	0.4524	0.138	0.095	0.009	-0.025	0.092	0.014
18	21.64	18	0.2483	0.109	-0.024	0.140	0.099	-0.081	-0.017
24	26.80	24	0.3138	-0.144	0.043	0.030	-0.021	0.032	-0.020
30	41.65	30	0.0767	-0.246	0.009	0.061	0.048	-0.049	-0.031
36	44.40	36	0.1589	0.039	-0.080	-0.064	0.011	-0.002	-0.016

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
72	Additive	3304.6	74.39	<.0001
74	Additive	1171.2	10.65	0.0011
80	Additive	1924.6	25.23	<.0001
107	Additive	1179.9	10.46	0.0012
133	Shift	898.9904	14.3	0.0002
147	Additive	1023.4	9.27	0.0023
159	Additive	2281.6	35.46	<.0001

Tests for Normality		
Test	Statistic	p Value
Shapiro-Wilk	W	0.97212 Pr < W 0.0008
Kolmogorov-Smirnov	D	0.061997 Pr > D 0.0774
Cramer-von Mises	W-Sq	0.204916 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	1.423108 Pr > A-Sq <0.0050




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.14	3	0.3712	-0.004	-0.075	0.028	0.050	0.077	0.037
12	13.99	9	0.1225	0.152	0.098	-0.030	0.014	0.099	-0.104
18	19.48	15	0.1929	0.100	-0.053	0.107	0.044	-0.023	-0.001
24	25.09	21	0.2432	-0.136	0.061	0.056	-0.033	-0.002	-0.004
30	28.05	27	0.4082	-0.044	-0.051	0.029	0.073	0.051	-0.005
36	28.90	33	0.6718	0.003	0.027	-0.044	0.020	-0.019	0.015

- Kargo Internasional yang Dimuat

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
125	Additive	-3309.6	10.43	0.0012
135	Additive	-4009.3	10.78	0.001
146	Additive	4395.9	12.46	0.0004
149	Additive	3484.6	11.44	0.0007
155	Additive	-3570.9	10.89	0.001
165	Additive	-4086	13.9	0.0002
188	Additive	-4887.2	15.24	<.0001


Tests for Normality		
Test	Statistic	p Value
Shapiro-Wilk	W	0.990825 Pr < W 0.3254
Kolmogorov-Smirnov	D	0.062912 Pr > D 0.0890
Cramer-von Mises	W-Sq	0.095228 Pr > W-Sq 0.1327
Anderson-Darling	A-Sq	0.540583 Pr > A-Sq 0.1698



Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
87	Additive	3504.2	9.29	0.0023
146	Additive	4685.7	12.14	0.0005
155	Additive	-3088	7.25	0.0071
158	Additive	-3527.9	8.81	0.003
188	Additive	-4844.8	11.76	0.0006

Tests for Normality		
Test	Statistic	p Value
Shapiro-Wilk	W	0.981047 Pr < W 0.1119
Kolmogorov-Smirnov	D	0.062097 Pr > D 0.0765
Cramer-von Mises	W-Sq	0.100166 Pr > W-Sq 0.1137
Anderson-Darling	A-Sq	0.800363 Pr > A-Sq 0.0393



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	10.75	6	0.0964	0.024	0.196	-0.063	0.129	0.005	0.008
12	19.64	12	0.0743	0.144	0.037	0.067	-0.058	0.073	-0.111
18	24.64	18	0.1351	-0.017	-0.111	-0.048	-0.016	-0.024	0.100
24	27.66	24	0.2745	0.058	-0.047	-0.048	-0.006	-0.021	-0.081
30	31.56	30	0.3884	-0.011	0.004	-0.001	0.040	0.059	-0.114


Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.65	4	0.1052	0.037	0.068	0.148	0.068	0.079	0.027
12	12.41	10	0.2588	0.059	0.023	0.110	0.037	0.075	0.028
18	23.76	16	0.0949	0.175	0.022	-0.065	0.102	0.000	0.097
24	32.25	22	0.0733	0.077	-0.105	0.037	0.064	-0.048	-0.122
30	35.14	28	0.1659	0.020	-0.000	0.014	-0.091	-0.010	-0.063
36	41.84	34	0.1672	-0.006	-0.088	-0.077	-0.099	0.029	-0.067

- Kargo Internasional yang Dibongkar

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
131	Additive	6625.2	23.84	<.0001
154	Additive	-7064.9	26.71	<.0001
165	Additive	-5319.5	15.72	<.0001
166	Additive	6402.1	22.43	<.0001

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.973016	Pr < W 0.0011
Kolmogorov-Smirnov	D	0.05913	Pr > D 0.1083
Cramer-von Mises	W-Sq	0.155437	Pr > W-Sq 0.0211
Anderson-Darling	A-Sq	1.082396	Pr > A-Sq 0.0079




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	11.10	6	0.0852	0.072	-0.146	0.118	0.128	0.008	0.034
12	16.61	12	0.1651	0.133	-0.054	-0.065	-0.009	-0.033	-0.044
18	20.54	18	0.3032	-0.005	-0.090	-0.001	-0.048	-0.052	-0.077
24	25.09	24	0.4009	-0.044	0.021	-0.042	0.094	0.077	-0.049
30	28.35	30	0.5521	0.065	0.054	-0.041	0.071	0.020	-0.024
36	34.86	36	0.5228	-0.033	0.016	0.067	0.033	0.043	-0.138

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
165	Additive	-5956.4	21.62	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.974329	Pr < W	0.0016
Kolmogorov-Smirnov	D	0.0589	Pr > D	0.1085
Cramer-von Mises	W-Sq	0.119242	Pr > W-Sq	0.0646
Anderson-Darling	A-Sq	0.890641	Pr > A-Sq	0.0230




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.23	3	0.1558	0.027	0.020	0.053	0.146	-0.027	0.033
12	10.46	9	0.3146	0.116	-0.083	-0.037	-0.044	-0.005	-0.052
18	19.13	15	0.2080	-0.050	-0.183	-0.001	0.041	0.042	0.053
24	31.19	21	0.0706	0.091	-0.061	-0.075	0.186	0.063	0.007
30	35.81	27	0.1196	0.021	0.049	-0.108	0.071	-0.032	-0.017
36	40.37	33	0.1766	-0.080	0.011	0.028	-0.013	0.054	-0.096

B. Bandara I Gusti Ngurah Rai

- Penumpang Domestik yang Berangkat


Model TSR

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.984809	Pr < W 0.0543
Kolmogorov-Smirnov	D	0.062582	Pr > D 0.0919
Cramer-von Mises	W-Sq	0.117478	Pr > W-Sq 0.0686
Anderson-Darling	A-Sq	0.77818	Pr > A-Sq 0.0439



Model ARIMAX

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.98021	Pr < W 0.0091
Kolmogorov-Smirnov	D	0.060024	Pr > D 0.0953
Cramer-von Mises	W-Sq	0.168776	Pr > W-Sq 0.0144
Anderson-Darling	A-Sq	1.139143	Pr > A-Sq 0.0056



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	8.66	6	0.1938	-0.077	0.064	0.005	0.104	0.163	0.022
12	17.96	12	0.1171	0.172	-0.089	0.038	-0.041	0.042	0.087
18	20.94	18	0.2823	-0.078	0.011	0.012	-0.031	0.033	-0.083
24	22.08	24	0.5742	0.041	-0.031	0.027	-0.045	-0.001	-0.017
30	31.60	30	0.3862	-0.005	0.133	-0.153	0.001	0.034	0.055


Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.96	4	0.2024	-0.120	0.040	0.053	0.067	0.063	-0.059
12	15.84	10	0.1042	0.142	-0.123	0.050	0.017	0.100	0.039
18	25.06	16	0.0688	-0.161	0.107	0.025	-0.053	-0.046	-0.046
24	29.39	22	0.1340	0.038	-0.026	0.099	-0.008	0.017	-0.089
30	40.70	28	0.0572	0.022	0.156	-0.147	-0.033	0.051	0.030
36	47.24	34	0.0651	-0.028	0.012	0.034	-0.085	0.135	0.025

- Penumpang Domestik yang Datang

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
125	Additive	-47605.1	11.89	0.0006
150	Additive	49816.1	13.23	0.0003

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.964797	Pr < W	0.0002
Kolmogorov-Smirnov	D	0.05905	Pr > D	0.1368
Cramer-von Mises	W-Sq	0.160497	Pr > W-Sq	0.0185
Anderson-Darling	A-Sq	1.0264	Pr > A-Sq	0.0104




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	8.96	6	0.1760	0.100	0.086	0.064	0.135	0.098	0.011
12	20.68	12	0.0552	0.092	0.089	0.094	0.037	0.081	0.170
18	25.21	18	0.1192	-0.082	-0.014	-0.085	-0.024	0.040	-0.083
24	28.17	24	0.2529	-0.063	0.012	0.073	-0.068	0.006	0.024
30	33.98	30	0.2816	-0.025	0.007	-0.113	-0.113	-0.014	-0.033

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
125	Additive	-55949.3	32.14	<.0001
150	Additive	40954.5	17.49	<.0001
179	Additive	-54457.4	26.44	<.0001

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.981976	Pr < W	0.0160
Kolmogorov-Smirnov	D	0.062041	Pr > D	0.0771
Cramer-von Mises	W-Sq	0.110888	Pr > W-Sq	0.0837
Anderson-Darling	A-Sq	0.634782	Pr > A-Sq	0.0974



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.34	3	0.2266	0.001	-0.040	-0.119	0.045	0.061	0.031
12	7.88	9	0.5458	0.077	-0.002	-0.016	-0.073	0.078	0.016
18	10.93	15	0.7574	-0.048	-0.034	0.055	-0.052	0.064	-0.038
24	15.31	21	0.8071	-0.012	-0.036	0.103	0.021	0.075	-0.046
30	22.31	27	0.7217	-0.087	0.117	-0.071	-0.055	0.035	0.033
36	28.42	33	0.6946	0.065	-0.050	-0.027	0.016	0.132	0.035

- Penumpang Internasional yang Berangkat

Model TSR


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
47	Additive	-37200	6.5	0.0108
68	Additive	-125761	66.81	<.0001
178	Additive	93791	37.77	<.0001
181	Additive	17277.8	10.6	0.0011

Tests for Normality				
Test		Statistic	p Value	
Shapiro-Wilk	W	0.968987	Pr < W	0.0025
Kolmogorov-Smirnov	D	0.055656	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.07113	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.501437	Pr > A-Sq	0.2125


Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx
178	Additive	139207.7	163.64	<.0001
183	Additive	-44232.3	19.24	<.0001

Tests for Normality				
Test		Statistic	p Value	
Shapiro-Wilk	W	0.928876	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.062635	Pr > D	0.0717
Cramer-von Mises	W-Sq	0.19969	Pr > W-Sq	0.0052
Anderson-Darling	A-Sq	1.363392	Pr > A-Sq	<0.0050



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	11.56	6	0.0725	0.246	0.125	0.012	-0.003	-0.029	0.040
12	18.25	12	0.1083	0.005	-0.070	-0.090	-0.133	-0.025	0.108
18	24.02	18	0.1545	-0.095	-0.066	-0.107	-0.099	-0.022	0.020
24	29.58	24	0.1989	0.084	0.042	-0.085	-0.056	0.005	0.116




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	6.24	4	0.1818	-0.017	-0.087	-0.028	-0.080	0.093	0.093
12	13.94	10	0.1758	0.085	-0.093	0.043	-0.048	-0.120	0.062
18	18.64	16	0.2877	-0.063	0.025	0.073	-0.067	0.087	0.025
24	22.64	22	0.4223	-0.047	-0.042	-0.005	0.011	-0.035	0.114
30	26.90	28	0.5240	-0.010	-0.008	-0.006	-0.086	-0.006	0.106
36	29.04	34	0.7091	0.050	0.071	0.020	0.021	-0.029	0.015

- Penumpang Internasional yang Datang

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
179	Additive	-76130.3	41.5	<.0001
180	Additive	64915.3	31.6	<.0001


Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.98791	Pr < W	0.1368
Kolmogorov-Smirnov	D	0.044148	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.066037	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.481883	Pr > A-Sq	0.2346



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.80	6	0.5702	-0.093	0.081	0.003	0.045	0.009	0.096
12	10.13	12	0.6042	0.027	-0.118	0.022	0.058	0.088	-0.047
18	16.93	18	0.5282	-0.084	0.031	-0.126	-0.088	0.016	-0.054
24	20.42	24	0.6727	-0.065	0.089	0.013	0.013	-0.043	0.055
30	29.10	30	0.5123	0.033	0.029	0.075	-0.132	0.084	0.096

Model ARIMAX

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.955989	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.060776	Pr > D	0.0885
Cramer-von Mises	W-Sq	0.131527	Pr > W-Sq	0.0433
Anderson-Darling	A-Sq	1.001596	Pr > A-Sq	0.0127



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	6.48	3	0.0904	-0.038	-0.143	-0.065	0.022	0.045	0.070
12	11.18	9	0.2634	0.040	-0.125	-0.013	-0.023	-0.003	0.075
18	17.65	15	0.2815	-0.057	-0.004	-0.086	-0.007	0.101	0.101
24	22.62	21	0.3648	-0.056	0.088	0.032	-0.037	-0.071	0.069
30	38.01	27	0.0776	0.087	-0.039	-0.030	-0.182	0.065	0.146
36	42.78	33	0.1185	0.076	0.005	0.005	0.003	-0.035	0.116

- Kargo Domestik yang Dimuat

Model TSR


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
32	Additive	554.2899	74.75	<.0001
168	Additive	-263.519	16.99	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.981583	Pr < W	0.0198
Kolmogorov-Smirnov	D	0.061869	Pr > D	0.0966
Cramer-von Mises	W-Sq	0.17042	Pr > W-Sq	0.0135
Anderson-Darling	A-Sq	0.948093	Pr > A-Sq	0.0177


Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
32	Additive	535.4129	65.8	<.0001
33	Additive	-312.0148	23.8	<.0001
50	Additive	280.0835	20.03	<.0001
56	Additive	-223.2366	13.44	0.0002
57	Additive	-154.3769	7.8	0.0052
90	Additive	-169.6654	8.47	0.0036
128	Additive	166.9444	8.94	0.0028
169	Additive	338.1686	26.52	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.993878	Pr < W	0.7790
Kolmogorov-Smirnov	D	0.049612	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.044267	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.265514	Pr > A-Sq	>0.2500



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	6.40	4	0.1710	0.024	0.077	-0.051	-0.097	-0.029	-0.125
12	13.96	10	0.1750	0.032	-0.016	0.103	-0.038	0.159	0.039
18	15.22	16	0.5084	-0.003	0.061	-0.010	0.000	-0.020	0.047
24	17.50	22	0.7353	-0.023	0.030	0.024	-0.025	0.084	-0.039
30	24.13	28	0.6747	-0.062	-0.089	-0.007	-0.035	0.018	0.134




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	6.40	4	0.1710	0.024	0.077	-0.051	-0.097	-0.029	-0.125
12	13.96	10	0.1750	0.032	-0.016	0.103	-0.038	0.159	0.039
18	15.22	16	0.5084	-0.003	0.061	-0.010	0.000	-0.020	0.047
24	17.50	22	0.7353	-0.023	0.030	0.024	-0.025	0.084	-0.039
30	24.13	28	0.6747	-0.062	-0.089	-0.007	-0.035	0.018	0.134

- Kargo Domestik yang Dibongkar

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
59	Additive	902.9349	56.15	<.0001
167	Additive	-1264.2	107.27	<.0001
168	Additive	-491.283	16.94	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.983999	Pr < W	0.0374
Kolmogorov-Smirnov	D	0.056884	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.109715	Pr > W-Sq	0.0863
Anderson-Darling	A-Sq	0.666186	Pr > A-Sq	0.0843




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	12.16	6	0.0585	-0.059	0.200	0.102	-0.024	0.063	-0.086
12	15.72	12	0.2044	0.128	0.013	-0.018	-0.008	-0.001	0.043
18	17.52	18	0.4877	-0.022	0.045	-0.039	-0.034	0.046	-0.041
24	19.93	24	0.7005	-0.009	0.039	-0.057	0.044	0.024	0.065
30	27.29	30	0.6082	0.117	0.037	0.114	0.057	0.057	0.005
36	26.90	36	0.7935	0.005	-0.011	-0.062	-0.004	-0.054	-0.013

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
12	Additive	317.0923	11.6	0.0007
32	Additive	288.4245	9.84	0.0017
167	Additive	-890.1073	100.73	<.0001
168	Additive	348.5814	14.02	0.0002

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.947077	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.061296	Pr > D	0.0838
Cramer-von Mises	W-Sq	0.21479	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.546672	Pr > A-Sq	<0.0050




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.61	4	0.4612	-0.030	-0.032	0.079	-0.062	0.010	-0.081
12	12.85	10	0.2321	0.082	0.069	-0.015	-0.118	0.099	0.103
18	16.73	16	0.4036	-0.011	0.088	0.084	0.026	0.035	-0.044
24	22.37	22	0.4381	-0.039	-0.049	-0.088	0.054	-0.108	-0.006
30	24.63	28	0.6478	0.018	0.066	0.039	-0.000	0.028	-0.056
36	36.49	34	0.3536	-0.052	-0.059	-0.032	0.033	-0.204	-0.032

- Kargo Internasional yang Dimuat


Model TSR

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.968627	Pr < W	0.0005
Kolmogorov-Smirnov	D	0.060644	Pr > D	0.1127
Cramer-von Mises	W-Sq	0.080417	Pr > W-Sq	0.2109
Anderson-Darling	A-Sq	0.684966	Pr > A-Sq	0.0765



Model ARIMAX

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.969802	Pr < W	0.0009
Kolmogorov-Smirnov	D	0.053587	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.094571	Pr > W-Sq	0.1352
Anderson-Darling	A-Sq	0.736067	Pr > A-Sq	0.0552



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.05	4	0.2822	-0.024	0.015	0.125	-0.101	0.027	0.021
12	12.58	10	0.2483	0.016	-0.094	0.110	0.025	-0.123	-0.054
18	23.97	16	0.0903	0.071	-0.064	0.058	0.096	-0.164	-0.098
24	33.13	22	0.0501	0.071	-0.036	-0.063	0.178	-0.028	-0.051
30	40.24	28	0.0630	0.116	-0.091	-0.080	0.015	0.033	-0.067


Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.33	6	0.6318	-0.033	0.056	0.105	-0.070	-0.014	0.065
12	11.71	12	0.4692	0.078	-0.050	0.159	0.015	-0.067	-0.043
18	18.15	18	0.4457	0.005	-0.016	0.040	0.082	-0.124	-0.098
24	25.82	24	0.3624	0.085	-0.062	-0.028	0.127	0.075	-0.072
30	34.52	30	0.2605	0.095	-0.120	-0.127	0.013	-0.007	-0.054

- Kargo Internasional yang Dibongkar

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
86	Additive	-278.113	4.84	0.0278
108	Additive	1306.8	81.04	<.0001
110	Additive	-1073.6	55.35	<.0001
149	Additive	-552.715	15.16	<.0001
167	Additive	-604.93	17.82	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.984913	Pr < W	0.0573
Kolmogorov-Smirnov	D	0.049701	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.082597	Pr > W-Sq	0.1980
Anderson-Darling	A-Sq	0.514312	Pr > A-Sq	0.1988




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.92	6	0.6873	-0.057	-0.091	0.014	0.053	-0.030	0.080
12	6.22	12	0.9046	0.034	-0.002	-0.033	0.081	-0.034	-0.048
18	14.56	18	0.6920	0.110	-0.124	-0.114	-0.003	0.039	0.039
24	17.10	24	0.8442	-0.023	-0.014	0.046	-0.065	-0.069	0.027
30	19.98	30	0.9170	0.085	-0.034	-0.022	0.042	0.056	0.007

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
17	Additive	390.8269	7.84	0.0051
86	Additive	531.2363	14.12	0.0002
108	Additive	743.1781	44.55	<.0001
109	Additive	969.9001	74.18	<.0001
159	Additive	265.6088	5.4	0.0201
167	Additive	-551.132	19.82	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.988428	Pr < W	0.1600
Kolmogorov-Smirnov	D	0.048075	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.051489	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.359682	Pr > A-Sq	>0.2500



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.44	4	0.3498	0.045	-0.052	-0.010	0.014	-0.139	-0.011
12	10.07	10	0.4345	0.125	-0.100	-0.024	0.049	0.000	0.039
18	25.25	16	0.0656	0.230	-0.044	-0.149	0.002	0.032	-0.017
24	27.29	22	0.2003	0.039	0.059	0.047	-0.048	-0.018	-0.018
30	29.68	28	0.3787	0.092	0.005	-0.017	0.007	0.028	-0.042

C. Bandara Juanda

- Penumpang Domestik yang Berangkat

Model TSR


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
30	Additive	63235.6	7.32	0.0068
35	Additive	63754.7	7.41	0.0065
151	Additive	-48188	5.97	0.0145
158	Additive	-75085	8.27	0.004
164	Additive	71145.5	7.5	0.0062
169	Additive	-66138.8	7.15	0.0075
170	Additive	-70410.4	7.62	0.0058

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.978839	Pr < W	0.0088
Kolmogorov-Smirnov	D	0.064583	Pr > D	0.0728
Cramer-von Mises	W-Sq	0.110816	Pr > W-Sq	0.0838
Anderson-Darling	A-Sq	0.6086	Pr > A-Sq	0.1141


Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
126	Additive	72640.7	12.25	0.0005
164	Additive	62612.6	9.9	0.0017

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.987027	Pr < W	0.0821
Kolmogorov-Smirnov	D	0.053962	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.11695	Pr > W-Sq	0.0699
Anderson-Darling	A-Sq	0.732806	Pr > A-Sq	0.0567



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.76	6	0.4506	-0.013	-0.046	-0.003	0.110	0.084	0.100
12	13.18	12	0.3560	-0.040	0.052	-0.005	-0.030	0.145	0.114
18	14.75	18	0.6792	-0.077	-0.005	0.031	-0.017	0.022	0.021
24	17.10	24	0.8442	0.048	-0.056	-0.005	0.054	0.033	-0.045
30	19.60	30	0.9266	-0.034	-0.003	0.007	-0.039	-0.057	-0.075




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.96	2	0.2271	-0.013	-0.050	-0.042	0.057	0.072	-0.049
12	6.50	8	0.5911	0.013	0.016	0.007	-0.088	0.097	0.002
18	17.05	14	0.2533	-0.051	0.109	0.084	-0.006	-0.141	-0.096
24	23.69	20	0.2564	0.055	0.065	0.050	-0.020	0.144	-0.006
30	29.93	26	0.2704	-0.026	0.017	0.011	-0.046	-0.054	-0.147
36	45.63	32	0.0560	0.081	-0.057	-0.043	-0.035	0.228	0.051

- Penumpang Domestik yang Datang

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
41	Additive	87606.6	14.04	0.0002
158	Additive	-89102.3	13.93	0.0002
170	Additive	-88639.1	13.8	0.0002

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.981555	Pr < W	0.0161
Kolmogorov-Smirnov	D	0.043696	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.077633	Pr > W-Sq	0.2274
Anderson-Darling	A-Sq	0.587022	Pr > A-Sq	0.1297




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.00	6	0.9198	0.005	0.057	-0.012	0.077	0.036	-0.002
12	7.49	12	0.8239	0.005	0.022	-0.100	0.063	-0.046	0.107
18	14.74	18	0.6900	-0.076	0.020	-0.097	0.048	0.037	0.128
24	16.97	24	0.8499	0.074	-0.003	0.056	0.009	0.041	-0.016
30	22.44	30	0.8375	0.023	-0.000	-0.102	-0.088	-0.079	-0.017
36	31.17	36	0.6977	-0.012	-0.092	-0.017	-0.112	0.110	0.070

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
36	Additive	-83987.8	16.74	<.0001
70	Additive	-45604.4	9.37	0.0022
96	Additive	-80598.1	16.78	<.0001
105	Additive	-37700.6	6.63	0.0101
129	Additive	62076.8	11.25	0.0008
150	Additive	45408.3	6.86	0.0088
162	Additive	34008.3	5.89	0.0152
168	Additive	33648.5	5.77	0.0163
180	Additive	89070.4	17.23	<.0001


Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.991641	Pr < W	0.3508
Kolmogorov-Smirnov	D	0.056843	Pr > D	0.1416
Cramer-von Mises	W-Sq	0.103323	Pr > W-Sq	0.1015
Anderson-Darling	A-Sq	0.567731	Pr > A-Sq	0.1435




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	9.02	4	0.0605	-0.134	0.123	-0.001	-0.074	0.077	-0.051
12	16.45	10	0.0875	0.119	-0.100	0.066	0.075	0.041	-0.040
18	19.80	16	0.2292	-0.057	-0.033	-0.069	0.040	0.044	-0.060
24	23.54	22	0.3718	0.095	-0.046	0.006	0.045	-0.018	0.063
30	25.60	28	0.5947	-0.058	0.037	-0.043	-0.035	-0.022	-0.033
36	26.67	34	0.8104	-0.043	-0.007	0.016	-0.016	-0.012	0.045

- Penumpang Internasional yang Berangkat

Model TSR



Model ARIMAX



- Penumpang Internasional yang Datang

Model TSR


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
38	Additive	19722.7	15.73	<.0001
50	Additive	60532.1	8.11	0.0044
96	Additive	22121.2	17.44	<.0001
108	Additive	50711.9	6.8	0.0091
143	Additive	-49849.9	6.31	0.012
145	Additive	12660.4	12.05	0.0005
147	Additive	55453	7.71	0.0055
150	Additive	55114	7.66	0.0056
151	Additive	-48188	5.97	0.0145
152	Additive	20165.9	21.73	<.0001
155	Additive	-59512.3	6.49	0.0108
157	Additive	51035.2	6.85	0.0089
167	Additive	-48339.3	5.93	0.0149
180	Additive	116048.2	22.56	<.0001

Model ARIMAX


Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
3	Additive	14156.3	9.22	0.0024
15	Additive	22688.6	19.07	<.0001
38	Additive	18717.3	18.41	<.0001
50	Additive	16479.3	14.27	0.0002
61	Additive	16835.3	14.01	0.0002
143	Additive	10425.4	6.57	0.0104

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.987288	Pr < W	0.0894
Kolmogorov-Smirnov	D	0.058798	Pr > D	0.1111
Cramer-von Mises	W-Sq	0.14476	Pr > W-Sq	0.0282
Anderson-Darling	A-Sq	0.798943	Pr > A-Sq	0.0396

Tests for Normality				
Test	Statistic		p Value	
Shapiro-Wilk	W	0.981777	Pr < W	0.0406
Kolmogorov-Smirnov	D	0.066764	Pr > D	0.0929
Cramer-von Mises	W-Sq	0.126899	Pr > W-Sq	0.0485
Anderson-Darling	A-Sq	0.825386	Pr > A-Sq	0.0340



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	9.44	6	0.1502	0.173	0.010	0.002	0.034	0.141	0.093
12	15.30	12	0.2254	0.031	0.041	0.151	-0.032	0.054	0.079
18	17.21	18	0.5088	0.025	-0.040	0.011	0.024	0.089	-0.009
24	26.91	24	0.3086	-0.008	0.068	0.177	0.071	-0.083	-0.077
30	35.52	30	0.2241	0.088	0.126	-0.076	-0.111	-0.000	-0.064




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.84	3	0.1837	-0.026	0.100	-0.097	0.043	0.050	-0.023
12	10.47	9	0.3141	0.019	-0.054	0.154	-0.031	0.000	-0.014
18	15.09	15	0.4453	-0.068	0.003	0.052	-0.056	0.007	-0.108
24	27.25	21	0.1629	0.025	-0.091	0.054	-0.152	0.145	0.027
30	35.52	27	0.1261	-0.078	0.043	-0.156	-0.035	-0.060	-0.015

- Kargo Domestik yang Dimuat

Model TSR

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
55	Additive	825.741	9.42	0.0021
63	Additive	-997.7759	12.17	0.0005
105	Additive	717.9756	7.41	0.0065
153	Additive	-917.0648	10.91	0.001

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.992716	Pr < W 0.6795
Kolmogorov-Smirnov	D	0.053205	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.07648	Pr > W-Sq 0.2338
Anderson-Darling	A-Sq	0.418749	Pr > A-Sq >0.2500




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	9.66	6	0.1399	-0.120	0.065	0.112	-0.092	0.095	0.127
12	12.03	12	0.4430	-0.059	0.066	0.075	0.043	-0.010	0.010
18	16.95	18	0.5268	-0.086	-0.006	-0.071	0.080	-0.100	-0.036
24	22.51	24	0.5489	-0.025	-0.171	-0.041	-0.012	-0.034	0.010

Model ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
93	Additive	-833.0524	16.75	<.0001
96	Additive	-839.008	16.71	<.0001
104	Additive	-846.5306	15.74	<.0001
107	Additive	-478.3565	6.09	0.0136
149	Additive	600.324	9.37	0.0022

Tests for Normality			
Test	Statistic	p Value	
Shapiro-Wilk	W	0.975832	Pr < W 0.0024
Kolmogorov-Smirnov	D	0.059396	Pr > D 0.1017
Cramer-von Mises	W-Sq	0.15471	Pr > W-Sq 0.0214
Anderson-Darling	A-Sq	1.049543	Pr > A-Sq 0.0092




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	8.58	5	0.1272	-0.173	0.042	-0.000	-0.019	0.044	0.103
12	14.89	11	0.1877	0.116	-0.101	0.071	0.025	0.048	0.010
18	17.51	17	0.4203	0.014	0.011	0.032	0.044	0.079	0.055
24	23.21	23	0.4483	0.071	-0.031	-0.091	0.081	-0.062	0.044
30	29.16	29	0.4569	-0.099	0.002	-0.095	0.024	0.040	-0.075
36	34.48	35	0.4932	-0.066	-0.100	0.022	0.066	-0.049	-0.037

- Kargo Domestik yang Dibongkar

TSR




ARIMAX




- Kargo Internasional yang Dimuat

TSR



ARIMAX




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.68	6	0.4605	-0.083	-0.008	-0.039	0.124	-0.017	-0.078
12	8.83	12	0.7173	0.067	-0.015	-0.064	-0.017	0.081	0.021
18	12.24	18	0.8348	-0.048	-0.001	-0.110	0.001	0.029	-0.040
24	14.25	24	0.9408	0.036	-0.003	0.064	-0.011	0.062	-0.013
30	15.32	30	0.9878	0.002	-0.020	-0.016	-0.030	0.058	0.003
36	19.89	36	0.9864	-0.053	-0.068	-0.048	-0.066	-0.071	-0.033

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.55	4	0.1094	-0.024	-0.117	-0.047	0.084	0.124	-0.005
12	15.93	10	0.1016	0.079	-0.020	-0.054	0.014	0.175	0.038
18	16.51	16	0.4183	-0.023	0.016	-0.013	0.038	0.017	0.009
24	19.36	22	0.6229	0.010	0.014	0.080	-0.051	0.061	-0.015
30	20.18	28	0.8579	-0.023	-0.025	-0.024	0.020	0.039	-0.001
36	22.01	34	0.9438	-0.035	-0.006	-0.059	-0.008	-0.036	-0.043

- Kargo Internasional yang Dibongkar

TSR

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.938725	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.060048	Pr > D	0.1294
Cramer-von Mises	W-Sq	0.164393	Pr > W-Sq	0.0166
Anderson-Darling	A-Sq	1.116246	Pr > A-Sq	0.0065




Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.00	6	0.5444	-0.123	0.037	0.098	-0.004	0.015	0.045
12	9.27	12	0.6793	0.062	0.032	-0.119	0.032	-0.019	0.052
18	11.28	18	0.8819	0.001	-0.058	-0.003	-0.074	-0.037	-0.012
24	15.52	24	0.9045	0.072	-0.076	-0.077	0.047	0.007	0.046
30	23.81	30	0.7805	0.080	-0.034	-0.068	0.152	-0.044	0.050

ARIMAX

Outlier Details				
Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
108	Additive	934.7793	53.15	<.0001

Tests for Normality				
Test	Statistic	p Value		
Shapiro-Wilk	W	0.988951	Pr < W	0.1532
Kolmogorov-Smirnov	D	0.045486	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.080893	Pr > W-Sq	0.2082
Anderson-Darling	A-Sq	0.561578	Pr > A-Sq	0.1480



Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	11.02	5	0.0511	-0.113	0.125	0.030	0.088	0.118	0.077
12	17.81	11	0.0862	0.077	0.105	0.019	0.005	0.009	0.128
18	20.15	17	0.2668	0.017	-0.031	0.071	0.025	-0.013	0.065
24	21.88	23	0.5278	0.044	0.007	-0.034	0.017	0.006	-0.067
30	25.17	29	0.6692	0.036	-0.032	0.032	0.049	-0.094	0.014
36	28.72	35	0.7643	0.104	-0.010	-0.007	-0.067	-0.000	-0.009

Lampiran 9. Hasil Estimasi Parameter Model TSR dan ARIMAX

A. Bandara Soekarno Hatta

- Penumpang Domestik yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	1871.2	482.51780	3.88	0.0002	0	t	0
NUM2	65295.6	23435.6	2.79	0.0081	0	S1	0
NUM3	124411.8	21784.2	5.71	<.0001	0	S3	0
NUM4	53030.8	21262.2	2.49	0.0138	0	S4	0
NUM5	98039.9	22734.1	4.31	<.0001	0	S5	0
NUM6	94528.6	22023.1	4.29	<.0001	0	S6	0
NUM7	218167.8	24024.9	9.08	<.0001	0	S7	0
NUM8	72143.2	22886.7	3.15	0.0020	0	S8	0
NUM9	102869.7	22334.7	4.61	<.0001	0	S9	0
NUM10	130727.2	22477.5	5.82	<.0001	0	S10	0
NUM11	106740.3	22672.3	4.71	<.0001	0	S11	0
NUM12	144340.5	24336.5	5.93	<.0001	0	S12	0
NUM13	-193870.2	30184.0	-6.42	<.0001	0	V1tmin1	0
NUM14	-133515.8	38404.0	-3.48	0.0007	0	V2tmin1	0
NUM15	-73477.7	33406.1	-2.20	0.0294	0	V3tmin1	0
NUM16	102287.9	38720.2	2.64	0.0092	0	V2t	0
NUM17	-127464.7	39567.0	-3.22	0.0016	0	V4t	0
NUM18	-99419.7	38833.9	-2.56	0.0115	0	V2tp1	0
NUM19	0.51563	0.04913	10.50	<.0001	0	lag1	0
NUM20	0.21280	0.05210	4.08	<.0001	0	lag5	0
NUM21	0.34046	0.05558	6.13	<.0001	0	lag12	0
NUM22	-0.29403	0.05835	-5.04	<.0001	0	lag13	0
NUM23	261248.6	66044.6	3.96	0.0001	0	A76	0
NUM24	-205098.1	67688.6	-3.03	0.0029	0	A88	0
NUM25	229903.9	65412.6	3.51	0.0006	0	A126	0
NUM26	269059.7	66460.2	4.05	<.0001	0	A152	0
NUM27	250327.5	67263.2	3.72	0.0003	0	A156	0
NUM28	-270644.9	65799.6	-4.11	<.0001	0	A158	0
NUM29	-258836.5	67163.2	-3.85	0.0002	0	A169	0
NUM30	-201792.4	67857.0	-2.97	0.0034	0	A171	0
NUM31	-237060.0	67404.2	-3.52	0.0006	0	A177	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.42949	0.07781	5.52	<.0001	1	Y1_t	0
AR1,2	0.22946	0.08060	2.85	0.0050	2	Y1_t	0
AR1,3	0.22396	0.06894	3.25	0.0014	5	Y1_t	0
AR2,1	0.33813	0.08555	3.95	0.0001	12	Y1_t	0
NUM1	9210.7	597.37165	15.42	<.0001	0	t	0
NUM2	155607.5	31274.5	4.98	<.0001	0	S1	0
NUM3	152005.7	31979.3	4.75	<.0001	0	S3	0
NUM4	103084.8	34499.8	2.99	0.0032	0	S4	0
NUM5	202010.0	37343.6	5.41	<.0001	0	S5	0
NUM6	198583.1	37863.1	5.24	<.0001	0	S6	0
NUM7	280622.7	34999.2	8.02	<.0001	0	S7	0
NUM8	184346.7	36292.7	5.08	<.0001	0	S8	0
NUM9	129224.5	35574.0	3.63	0.0004	0	S9	0
NUM10	185820.4	38514.7	4.82	<.0001	0	S10	0
NUM11	189484.9	37922.0	5.00	<.0001	0	S11	0
NUM12	287312.7	34831.7	8.25	<.0001	0	S12	0
NUM13	-156680.2	31227.6	-5.02	<.0001	0	V1tmin1	0
NUM14	80504.8	37999.6	2.12	0.0356	0	V2t	0
NUM15	-188800.9	38693.6	-4.88	<.0001	0	V4t	0
NUM16	287037.5	65698.3	4.37	<.0001	0	A76	0
NUM17	140584.5	65466.3	2.15	0.0332	0	A156	0

- Penumpang Domestik yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	1028.4	443.03240	2.32	0.0216	0	t	0
NUM2	-118075.8	29381.1	-4.02	<.0001	0	S2	0
NUM3	102923.1	27964.1	3.68	0.0003	0	S3	0
NUM4	57529.2	28450.3	2.02	0.0449	0	S4	0
NUM5	89995.3	26252.6	3.43	0.0008	0	S5	0
NUM6	121232.9	28751.2	4.23	<.0001	0	S6	0
NUM7	143542.5	27475.2	5.22	<.0001	0	S7	0
NUM8	-251919.7	43784.2	-5.78	<.0001	0	V1tmin1	0
NUM9	209829.1	46407.1	4.52	<.0001	0	V1t	0
NUM10	127860.0	56883.2	2.25	0.0282	0	V2t	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.65072	0.07834	8.31	<.0001	1	Y2_t	0
AR1,2	0.22938	0.07897	2.90	0.0042	2	Y2_t	0
AR2,1	0.34808	0.08372	4.16	<.0001	12	Y2_t	0
NUM1	11132.0	844.41001	13.18	<.0001	0	t	0
NUM2	182175.7	39030.3	4.67	<.0001	0	S1	0
NUM3	161257.9	40373.3	3.99	<.0001	0	S3	0
NUM4	152947.6	47499.6	3.22	0.0015	0	S4	0
NUM5	232837.9	53216.7	4.38	<.0001	0	S5	0
NUM6	302892.1	56809.8	5.33	<.0001	0	S6	0
NUM7	392474.4	59122.5	6.64	<.0001	0	S7	0
NUM8	314869.0	59749.3	5.27	<.0001	0	S8	0
NUM9	254165.8	59198.1	4.29	<.0001	0	S9	0
NUM10	259858.2	57084.6	4.55	<.0001	0	S10	0

NUM11	128507.5	43559.6	2.95	0.0037	0	V3tpl1	0
NUM12	231785.4	59085.7	3.92	0.0001	0	V4tpl1	0
NUM13	0.52537	0.05406	9.72	<.0001	0	lag1	0
NUM14	0.28982	0.05523	5.25	<.0001	0	lag2	0
NUM15	0.10857	0.04446	2.44	0.0158	0	lag12	0
NUM16	322468.9	99302.1	3.25	0.0014	0	A76	0
NUM17	-321435.6	97284.7	-3.30	0.0012	0	A128	0
NUM18	-447359.3	96092.3	-4.66	<.0001	0	A157	0
NUM19	-415631.8	101181.8	-4.11	<.0001	0	A158	0
NUM20	-289607.3	102033.9	-2.64	0.0091	0	A160	0
NUM21	-435238.5	99138.6	-4.39	<.0001	0	A163	0
NUM22	-291462.5	96971.0	-3.01	0.0031	0	A169	0
NUM23	-251750.4	102057.2	-2.47	0.0147	0	A170	0
NUM24	-469035.1	96090.6	-4.88	<.0001	0	A177	0

NUM11	264470.6	53194.6	4.97	<.0001	0	S11	0
NUM12	303092.4	47003.6	6.45	<.0001	0	S12	0
NUM13	-249799.6	39194.2	-6.37	<.0001	0	V1tmin1	0
NUM14	-125372.7	48301.3	-2.60	0.0103	0	V2tmin1	0
NUM15	-339243.1	48808.1	-6.95	<.0001	0	V4t	0
NUM16	136992.9	37490.4	3.65	0.0003	0	V3tpl1	0
NUM17	287861.7	82794.8	3.48	0.0006	0	A76	0
NUM18	-268757.3	83337.4	-3.22	0.0015	0	A160	0

- Penumpang Internasional yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	243.80592	119.89447	2.03	0.0437	0	t	0
NUM2	24012.8	8850.2	2.71	0.0074	0	S3	0
NUM3	30001.8	7683.7	3.90	0.0001	0	S5	0
NUM4	27048.1	8270.6	3.27	0.0013	0	S6	0
NUM5	21594.6	8099.1	2.67	0.0085	0	S7	0
NUM6	27139.8	7773.4	3.49	0.0006	0	S8	0
NUM7	67073.3	8922.0	7.52	<.0001	0	S12	0
NUM8	28368.8	12605.5	2.25	0.0258	0	V1tpl1	0
NUM9	-64433.4	16337.7	-3.94	0.0001	0	V4tpl1	0
NUM10	0.34729	0.04921	7.06	<.0001	0	lag1	0
NUM11	0.23986	0.05309	4.52	<.0001	0	lag3	0
NUM12	0.32674	0.05683	5.75	<.0001	0	lag12	0
NUM13	60279.7	27595.4	2.18	0.0304	0	A37	0
NUM14	-83679.2	28095.7	-2.98	0.0034	0	A96	0
NUM15	80025.5	27998.4	2.86	0.0048	0	A126	0
NUM16	68893.8	28238.6	2.44	0.0158	0	A147	0
NUM17	-61053.9	28126.8	-2.17	0.0314	0	A151	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.70240	0.05667	12.40	<.0001	1	Y3_1t	0
AR2,1	0.77757	0.05816	13.37	<.0001	12	Y3_1t	0
NUM1	2058.9	207.07065	9.94	<.0001	0	t	0
NUM2	156495.4	20030.3	7.81	<.0001	0	S1	0
NUM3	161660.1	23874.0	6.77	<.0001	0	S2	0
NUM4	173655.5	25387.7	6.84	<.0001	0	S3	0
NUM5	152983.1	26373.0	5.80	<.0001	0	S4	0
NUM6	159501.7	26903.5	5.93	<.0001	0	S5	0
NUM7	179149.8	27190.9	6.59	<.0001	0	S6	0
NUM8	175427.9	27244.2	6.44	<.0001	0	S7	0
NUM9	178173.1	27158.8	6.56	<.0001	0	S8	0
NUM10	162442.0	26699.2	6.08	<.0001	0	S9	0
NUM11	141807.2	25801.9	5.50	<.0001	0	S10	0
NUM12	128172.1	24010.1	5.34	<.0001	0	S11	0
NUM13	208606.2	20376.0	10.24	<.0001	0	S12	0
NUM14	-20437.9	8819.0	-2.32	0.0217	0	V2tmin1	0
NUM15	-19094.1	9041.4	-2.11	0.0362	0	V1t	0
NUM16	30512.2	9343.6	3.27	0.0013	0	V1tpl1	0
NUM17	-36638.7	10105.2	-3.63	0.0004	0	V4tpl1	0
NUM18	-32816.6	15000.2	-2.19	0.0301	0	A28	0
NUM19	53460.4	17427.4	3.07	0.0025	0	A60	0
NUM20	-45649.9	17854.0	-2.56	0.0115	0	A130	0
NUM21	51674.0	17390.8	2.97	0.0034	0	A142	0
NUM22	96399.0	17610.5	5.47	<.0001	0	A152	0
NUM23	-57315.7	15019.0	-3.82	0.0002	0	A160	0
NUM24	71213.9	17350.3	4.10	<.0001	0	A176	0

- Penumpang Internasional yang Datang

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	254.26403	122.19133	2.08	0.0391	0	t	0
NUM2	44071.4	9487.3	4.65	<.0001	0	S1	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.52872	0.07038	7.51	<.0001	1	Y4_1t	0
AR1,2	0.16980	0.07311	2.32	0.0214	3	Y4_1t	0

NUM3	-29163.5	9674.0	-3.01	0.0030	0	S2	0
NUM4	42183.2	9689.8	4.35	<.0001	0	S3	0
NUM5	32433.3	9647.8	3.36	0.0010	0	S5	0
NUM6	33742.3	9459.4	3.57	0.0005	0	S6	0
NUM7	75406.4	10763.7	7.01	<.0001	0	S7	0
NUM8	30447.3	10074.6	3.02	0.0029	0	S11	0
NUM9	-46055.0	14827.6	-3.11	0.0023	0	V1tmin1	0
NUM10	41328.2	19098.7	2.16	0.0320	0	V2t	0
NUM11	-56973.2	19150.8	-2.97	0.0034	0	V4t	0
NUM12	-42440.2	19074.9	-2.22	0.0275	0	V2tpl1	0
NUM13	77784.5	23364.0	3.33	0.0011	0	V4tpl1	0
NUM14	0.36705	0.05287	6.94	<.0001	0	lag1	0
NUM15	0.18058	0.05871	3.08	0.0025	0	lag3	0
NUM16	0.14713	0.05883	2.50	0.0134	0	lag9	0
NUM17	0.20856	0.06699	3.11	0.0022	0	lag12	0
NUM18	105234.1	32064.5	3.28	0.0013	0	A108	0
NUM19	-69320.6	33365.4	-2.08	0.0394	0	A158	0
NUM20	-135012.9	41001.1	-3.29	0.0012	0	A164	0

AR1,3	0.16322	0.06332	2.58	0.0108	9	Y4_1t	0
AR2,1	0.39229	0.07424	5.28	<.0001	12	Y4_1t	0
AR2,2	0.37358	0.07376	5.06	<.0001	23	Y4_1t	0
NUM1	1676.4	351.82076	4.76	<.0001	0	t	0
NUM2	233925.8	20547.2	11.38	<.0001	0	S1	0
NUM3	152648.6	21226.7	7.19	<.0001	0	S2	0
NUM4	220654.5	21757.5	10.14	<.0001	0	S3	0
NUM5	201625.3	22276.1	9.05	<.0001	0	S4	0
NUM6	204296.3	22783.7	8.97	<.0001	0	S5	0
NUM7	221178.1	23024.2	9.61	<.0001	0	S6	0
NUM8	266532.8	23081.3	11.55	<.0001	0	S7	0
NUM9	206378.6	22900.2	9.01	<.0001	0	S8	0
NUM10	187017.5	22533.2	8.30	<.0001	0	S9	0
NUM11	182522.3	22068.5	8.27	<.0001	0	S10	0
NUM12	193284.8	21715.9	8.90	<.0001	0	S11	0
NUM13	208015.9	21009.7	9.90	<.0001	0	S12	0
NUM14	-38515.5	10850.8	-3.55	0.0005	0	V1tmin1	0
NUM15	23819.9	12227.8	1.95	0.0531	0	V2t	0
NUM16	-50853.2	13421.1	-3.79	0.0002	0	V4t	0
NUM17	-204783.7	21341.8	-9.60	<.0001	0	A24	0
NUM18	-86510.2	20683.1	-4.18	<.0001	0	A61	0

- Kargo Domestik yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	22.35910	4.34383	5.15	<.0001	0	t	0
NUM2	1266.5	382.49485	3.31	0.0012	0	S1	0
NUM3	1821.4	382.70214	4.76	<.0001	0	S3	0
NUM4	1265.3	363.83542	3.48	0.0007	0	S4	0
NUM5	2377.5	345.42376	6.88	<.0001	0	S5	0
NUM6	2153.8	362.27678	5.95	<.0001	0	S6	0
NUM7	1597.0	374.51622	4.26	<.0001	0	S7	0
NUM8	1749.6	370.24272	4.73	<.0001	0	S8	0
NUM9	1289.0	388.34966	3.32	0.0011	0	S9	0
NUM10	2041.4	392.67941	5.20	<.0001	0	S10	0
NUM11	1746.3	400.81327	4.36	<.0001	0	S11	0
NUM12	3207.1	376.19754	8.52	<.0001	0	S12	0
NUM13	1971.3	656.51310	3.00	0.0031	0	V2min1	0
NUM14	1043.0	508.98294	2.05	0.0421	0	V3min1	0
NUM15	-3182.3	570.48526	-5.58	<.0001	0	V1t	0
NUM16	-2265.0	682.84580	-3.32	0.0011	0	V2t	0
NUM17	-2327.5	512.95335	-4.54	<.0001	0	V3t	0
NUM18	1856.6	811.41024	2.29	0.0235	0	V2tpl1	0
NUM19	0.36509	0.05028	7.26	<.0001	0	lag1	0
NUM20	0.34585	0.05427	6.37	<.0001	0	lag3	0
NUM21	-3641.8	1397.0	-2.61	0.0100	0	A48	0
NUM22	-4725.0	1139.3	-4.15	<.0001	0	A107	0
NUM23	4776.9	1130.1	4.23	<.0001	0	A124	0
NUM24	3733.5	1141.3	3.27	0.0013	0	A131	0
NUM25	-2842.3	1170.0	-2.43	0.0162	0	A134	0
NUM26	3075.4	1135.9	2.71	0.0075	0	A151	0
NUM27	-2995.3	1279.5	-2.34	0.0205	0	A152	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.39887	0.07014	5.68	<.0001	1	Z1_1t	0
AR1,2	0.37407	0.07180	5.21	<.0001	3	Z1_1t	0
NUM1	74.53592	5.04996	14.76	<.0001	0	t	0
NUM2	5528.2	564.47878	9.79	<.0001	0	S1	0
NUM3	4010.1	571.87543	7.01	<.0001	0	S2	0
NUM4	5449.4	572.98841	9.51	<.0001	0	S3	0
NUM5	5162.2	581.84370	8.87	<.0001	0	S4	0
NUM6	5718.5	584.30943	9.79	<.0001	0	S5	0
NUM7	6089.0	586.53450	10.38	<.0001	0	S6	0
NUM8	5851.3	596.99601	9.80	<.0001	0	S7	0
NUM9	5534.6	594.71415	9.31	<.0001	0	S8	0
NUM10	5304.5	594.74851	8.92	<.0001	0	S9	0
NUM11	6013.6	589.77945	10.20	<.0001	0	S10	0
NUM12	5734.3	597.22151	9.60	<.0001	0	S11	0
NUM13	6795.0	583.61263	11.64	<.0001	0	S12	0
NUM14	1920.4	562.68358	3.41	0.0008	0	V2min1	0
NUM15	1128.8	434.44536	2.60	0.0102	0	V3min1	0
NUM16	-3185.7	418.03990	-7.62	<.0001	0	V1t	0
NUM17	-2139.6	568.62368	-3.76	0.0002	0	V2t	0
NUM18	-1837.5	430.15795	-4.27	<.0001	0	V3t	0
NUM19	-3354.6	940.98653	-3.56	0.0005	0	A79	0
NUM20	-4307.8	943.14260	-4.57	<.0001	0	A107	0
NUM21	4351.5	924.19330	4.71	<.0001	0	A124	0
NUM22	4016.5	934.18839	4.30	<.0001	0	A131	0
NUM23	3424.0	942.09601	3.63	0.0004	0	A151	0

- Kargo Domestik yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-781.02936	170.13126	-4.59	<.0001	0	S2	0
NUM2	305.09855	167.62392	1.82	0.0705	0	S11	0
NUM3	553.99754	172.16952	3.22	0.0016	0	S12	0
NUM4	-1151.4	280.90655	-4.10	<.0001	0	V1t	0
NUM5	-1187.5	362.75599	-3.27	0.0013	0	V2t	0
NUM6	0.46645	0.05629	8.29	<.0001	0	lag1	0
NUM7	0.33324	0.05447	6.12	<.0001	0	lag2	0
NUM8	0.20411	0.04478	4.56	<.0001	0	lag8	0
NUM9	4077.3	635.71864	6.41	<.0001	0	A72	0
NUM10	-2091.3	667.88941	-3.13	0.0021	0	A73	0
NUM11	2117.5	615.65934	3.44	0.0007	0	A79	0
NUM12	-2919.7	633.63847	-4.61	<.0001	0	A135	0
NUM13	3122.4	627.86271	4.97	<.0001	0	A136	0
NUM14	1958.3	620.21490	3.16	0.0019	0	A147	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.53409	0.08746	6.11	<.0001	1	Z2_1t	0
AR1,2	0.23768	0.08740	2.72	0.0072	2	Z2_1t	0
AR1,3	0.22473	0.05802	3.87	0.0002	8	Z2_1t	0
NUM1	2947.9	464.88563	6.34	<.0001	0	S1	0
NUM2	2197.5	471.85195	4.66	<.0001	0	S2	0
NUM3	2602.9	479.96705	5.42	<.0001	0	S3	0
NUM4	2627.2	480.07738	5.47	<.0001	0	S4	0
NUM5	2788.0	482.04018	5.78	<.0001	0	S5	0
NUM6	2816.9	485.57681	5.80	<.0001	0	S6	0
NUM7	3004.3	486.96475	6.17	<.0001	0	S7	0
NUM8	2868.1	486.70079	5.89	<.0001	0	S8	0
NUM9	2848.1	487.71892	5.84	<.0001	0	S9	0
NUM10	2742.3	487.12761	5.63	<.0001	0	S10	0
NUM11	2825.5	485.13811	5.82	<.0001	0	S11	0
NUM12	3254.6	481.02075	6.77	<.0001	0	S12	0
NUM13	-962.88812	219.07292	-4.40	<.0001	0	V1t	0
NUM14	-746.49678	284.05710	-2.63	0.0094	0	V2t	0
NUM15	-516.84100	219.97356	-2.35	0.0200	0	V3t	0
NUM16	4061.4	513.27067	7.91	<.0001	0	A72	0
NUM17	1430.2	504.83219	2.83	0.0052	0	A74	0
NUM18	2106.9	536.23402	3.93	0.0001	0	A80	0
NUM19	1164.8	502.27006	2.32	0.0216	0	A107	0
NUM20	1047.7	485.33132	2.16	0.0323	0	A133	0
NUM21	-3420.5	521.61363	-6.56	<.0001	0	A135	0
NUM22	1699.6	515.85180	3.29	0.0012	0	A147	0
NUM23	2387.6	502.51436	4.75	<.0001	0	A159	0

- Kargo Internasional yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	15.35245	3.46674	4.43	<.0001	0	t	0
NUM2	2767.2	676.04756	4.09	<.0001	0	S1	0
NUM3	1668.9	692.07745	2.41	0.0171	0	S2	0
NUM4	3915.8	667.64788	5.87	<.0001	0	S3	0
NUM5	2149.4	744.54104	2.89	0.0045	0	S4	0
NUM6	2707.0	714.37023	3.79	0.0002	0	S5	0
NUM7	1433.2	705.51691	2.03	0.0440	0	S6	0
NUM8	2640.0	639.00501	4.13	<.0001	0	S7	0
NUM9	2397.9	668.98633	3.58	0.0005	0	S8	0
NUM10	2927.8	672.51084	4.35	<.0001	0	S9	0
NUM11	3143.8	688.01771	4.57	<.0001	0	S10	0
NUM12	2883.1	729.51350	3.95	0.0001	0	S11	0
NUM13	2338.3	702.98318	3.33	0.0011	0	S12	0
NUM14	-1196.5	655.23051	-1.83	0.0698	0	V1tmin1	0
NUM15	-1454.3	652.50190	-2.23	0.0273	0	V1t	0
NUM16	0.47866	0.06305	7.59	<.0001	0	lag1	0
NUM17	0.11083	0.06425	1.73	0.0866	0	lag13	0
NUM18	-3324.4	1458.8	-2.28	0.0241	0	A125	0
NUM19	-4451.1	1460.9	-3.05	0.0027	0	A135	0
NUM20	4658.4	1464.3	3.18	0.0018	0	A146	0
NUM21	3304.1	1468.3	2.25	0.0259	0	A149	0
NUM22	-3884.6	1498.6	-2.59	0.0105	0	A155	0
NUM23	-3718.4	1491.1	-2.49	0.0137	0	A165	0
NUM24	-5369.5	1466.9	-3.66	0.0003	0	A188	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.50606	0.07758	-6.52	<.0001	1	Z3_1t	0
MA1,2	-0.33065	0.07513	-4.40	<.0001	2	Z3_1t	0
NUM1	31.29520	3.48424	8.98	<.0001	0	t	0
NUM2	6729.4	513.75355	13.10	<.0001	0	S1	0
NUM3	6020.3	530.12845	11.36	<.0001	0	S2	0
NUM4	7261.8	532.26268	13.64	<.0001	0	S3	0
NUM5	6799.1	527.96868	12.88	<.0001	0	S4	0
NUM6	6892.9	530.13713	13.00	<.0001	0	S5	0
NUM7	5739.5	532.31955	10.78	<.0001	0	S6	0
NUM8	6210.9	535.04514	11.61	<.0001	0	S7	0
NUM9	6298.0	539.51864	11.67	<.0001	0	S8	0
NUM10	6525.0	538.04899	12.13	<.0001	0	S9	0
NUM11	6979.5	539.36108	12.94	<.0001	0	S10	0
NUM12	6950.4	542.77732	12.81	<.0001	0	S11	0
NUM13	6442.6	531.74860	12.12	<.0001	0	S12	0
NUM14	-1272.3	590.89626	-2.15	0.0327	0	V1t	0
NUM15	3125.4	1281.7	2.44	0.0158	0	A87	0
NUM16	6189.4	1285.6	4.81	<.0001	0	A146	0
NUM17	-2909.3	1355.6	-2.15	0.0333	0	A155	0
NUM18	-3786.1	1309.1	-2.89	0.0043	0	A158	0
NUM19	-5531.2	1538.7	-3.59	0.0004	0	A188	0

- Kargo Internasional yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	15.56041	3.01913	5.15	<.0001	0	t	0
NUM2	2139.0	536.13117	3.99	<.0001	0	S1	0
NUM3	1569.2	523.13186	3.00	0.0031	0	S2	0
NUM4	3716.1	505.24699	7.35	<.0001	0	S3	0
NUM5	2819.4	585.07719	4.99	<.0001	0	S4	0
NUM6	3608.3	570.37823	6.33	<.0001	0	S5	0
NUM7	2157.3	604.00779	3.57	0.0005	0	S6	0
NUM8	2018.5	571.48040	3.53	0.0005	0	S7	0
NUM9	2423.5	541.49212	4.48	<.0001	0	S8	0
NUM10	3244.5	552.79327	5.87	<.0001	0	S9	0
NUM11	2804.7	578.11704	4.85	<.0001	0	S10	0
NUM12	2083.7	572.99924	3.64	0.0004	0	S11	0
NUM13	2010.4	551.37868	3.65	0.0004	0	S12	0
NUM14	-2659.5	943.42502	-2.82	0.0054	0	V2t	0
NUM15	-1482.0	724.65588	-2.05	0.0424	0	V3t	0
NUM16	-1873.3	933.79236	-2.01	0.0465	0	V4t	0
NUM17	0.56809	0.05806	9.79	<.0001	0	lag1	0
NUM18	7445.7	1627.7	4.57	<.0001	0	A131	0
NUM19	-7131.9	1634.0	-4.36	<.0001	0	A154	0
NUM20	-5663.2	1629.9	-3.47	0.0007	0	A165	0
NUM21	5878.6	1671.2	4.12	<.0001	0	A166	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.50536	0.07554	-6.69	<.0001	1	Z4_1t	0
MA1,2	-0.19412	0.08392	-2.31	0.0219	2	Z4_1t	0
MA1,3	-0.21030	0.07636	-2.75	0.0065	3	Z4_1t	0
NUM1	36.24987	4.43122	8.18	<.0001	0	t	0
NUM2	5006.4	638.83136	7.84	<.0001	0	S1	0
NUM3	4384.0	647.83804	6.77	<.0001	0	S2	0
NUM4	6176.6	651.51712	9.48	<.0001	0	S3	0
NUM5	6296.5	656.50304	9.59	<.0001	0	S4	0
NUM6	7155.6	659.32348	10.85	<.0001	0	S5	0
NUM7	6192.5	662.16148	9.35	<.0001	0	S6	0
NUM8	5386.3	666.31839	8.08	<.0001	0	S7	0
NUM9	5131.6	672.22122	7.63	<.0001	0	S8	0
NUM10	5903.6	681.39669	8.66	<.0001	0	S9	0
NUM11	5543.4	673.65616	8.23	<.0001	0	S10	0
NUM12	5457.0	668.03589	8.17	<.0001	0	S11	0
NUM13	5097.0	661.51486	7.71	<.0001	0	S12	0
NUM14	2412.1	898.75910	2.68	0.0080	0	V2tmin1	0
NUM15	-1432.0	698.00164	-2.05	0.0418	0	V3t	0
NUM16	-7230.0	1602.4	-4.51	<.0001	0	A165	0

B. Bandara I Gusti Ngurah Rai

- Penumpang Domestik yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	399.86442	106.73712	3.75	0.0003	0	t	0
NUM2	12620.8	5876.2	2.15	0.0333	0	S1	0
NUM3	-16629.1	5577.1	-2.98	0.0033	0	S2	0
NUM4	11242.0	4884.7	2.30	0.0227	0	S5	0
NUM5	25485.5	5035.1	5.06	<.0001	0	S7	0
NUM6	9325.5	5513.6	1.69	0.0927	0	S8	0
NUM7	7623.4	5039.0	1.51	0.1323	0	S10	0
NUM8	-46303.2	8172.2	-5.67	<.0001	0	V1tmin1	0
NUM9	-21702.3	10427.8	-2.08	0.0390	0	V2tmin1	0
NUM10	43386.5	8151.8	5.32	<.0001	0	V1t	0
NUM11	26062.8	10272.5	2.54	0.0121	0	V2t	0
NUM12	-37475.4	10851.0	-3.45	0.0007	0	V4t	0
NUM13	49431.1	10500.1	4.71	<.0001	0	V4tpl1	0
NUM14	0.70730	0.05282	13.39	<.0001	0	lag1	0
NUM15	0.23321	0.06732	3.46	0.0007	0	lag11	0
NUM16	0.25662	0.07068	3.63	0.0004	0	lag12	0
NUM17	-0.38775	0.06936	-5.59	<.0001	0	lag13	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.76679	0.05270	14.55	<.0001	1	Y1_2t	0
AR2,1	0.39956	0.09222	4.33	<.0001	12	Y1_2t	0
NUM1	1959.6	87.90256	22.29	<.0001	0	t	0
NUM2	38667.3	6790.0	5.69	<.0001	0	S1	0
NUM3	24413.9	7289.9	3.35	0.0010	0	S5	0
NUM4	33233.2	9358.3	3.55	0.0005	0	S6	0
NUM5	64170.4	10528.2	6.10	<.0001	0	S7	0
NUM6	55027.2	11075.4	4.97	<.0001	0	S8	0
NUM7	31414.6	11158.6	2.82	0.0054	0	S9	0
NUM8	36466.5	10949.1	3.33	0.0011	0	S10	0
NUM9	33043.8	10282.7	3.21	0.0016	0	S11	0
NUM10	38639.1	9026.0	4.28	<.0001	0	S12	0
NUM11	-50751.4	6257.8	-8.11	<.0001	0	V1tmin1	0
NUM12	-52507.0	9085.8	-5.78	<.0001	0	V4t	0
NUM13	-13856.5	6199.2	-2.24	0.0267	0	V3t	0
NUM14	21518.4	8693.5	2.48	0.0143	0	V4tpl1	0

- Penumpang Domestik yang Datang

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	222 95072	107.99708	2.06	0.0406	0	t	0
NUM2	-21696.0	5513.4	-3.94	0.0001	0	S1	0
NUM3	-31636.7	5841.2	-5.42	<.0001	0	S2	0
NUM4	18210.1	4991.2	3.65	0.0004	0	S5	0
NUM5	18776.0	5124.6	3.66	0.0003	0	S6	0
NUM6	27397.8	5113.9	5.36	<.0001	0	S7	0
NUM7	30844.7	5332.0	5.78	<.0001	0	S12	0
NUM8	-49616.2	8431.1	-5.88	<.0001	0	V1tmin1	0
NUM9	-32581.3	10410.5	-3.13	0.0021	0	V2tmin1	0
NUM10	-24556.9	9109.6	-2.70	0.0078	0	V3tmin1	0
NUM11	19501.4	8689.1	2.24	0.0262	0	V1t	0
NUM12	-26043.2	10731.1	-2.43	0.0163	0	V4t	0
NUM13	0.39369	0.05945	6.62	<.0001	0	lag1	0
NUM14	0.33005	0.05817	5.67	<.0001	0	lag2	0
NUM15	0.20056	0.05670	3.54	0.0005	0	lag12	0
NUM16	-51773.1	18291.7	-2.83	0.0052	0	A125	0
NUM17	50426.8	18332.3	2.75	0.0066	0	A150	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.56212	0.07731	7.27	<.0001	1	Y2_2t	0
AR1,2	0.31051	0.07928	3.92	0.0001	2	Y2_2t	0
AR2,1	0.47307	0.07923	5.97	<.0001	12	Y2_2t	0
NUM1	1806.4	157.25947	11.49	<.0001	0	t	0
NUM2	54075.6	12631.1	4.28	<.0001	0	S1	0
NUM3	35020.7	13147.5	2.66	0.0085	0	S2	0
NUM4	47027.9	13727.1	3.43	0.0008	0	S3	0
NUM5	46992.0	14083.0	3.34	0.0010	0	S4	0
NUM6	67537.1	14375.2	4.70	<.0001	0	S5	0
NUM7	74009.3	14543.7	5.09	<.0001	0	S6	0
NUM8	98949.2	14615.5	6.77	<.0001	0	S7	0
NUM9	88480.0	14534.6	6.09	<.0001	0	S8	0
NUM10	73048.4	14346.8	5.09	<.0001	0	S9	0
NUM11	78565.4	14023.2	5.60	<.0001	0	S10	0
NUM12	73134.4	13595.4	5.38	<.0001	0	S11	0
NUM13	103911.7	13064.9	7.95	<.0001	0	S12	0
NUM14	-48472.1	5828.5	-8.32	<.0001	0	V1tmin1	0
NUM15	-34997.8	7006.9	-4.99	<.0001	0	V2tmin1	0
NUM16	-14015.4	5702.4	-2.46	0.0150	0	V3tmin1	0
NUM17	-26938.0	5581.6	-4.83	<.0001	0	V3t	0
NUM18	-36677.0	6986.1	-5.25	<.0001	0	V4t	0
NUM19	-58836.8	11378.7	-5.17	<.0001	0	A125	0
NUM20	41451.5	11523.0	3.60	0.0004	0	A150	0
NUM21	-60809.4	13081.0	-4.65	<.0001	0	A179	0

- Penumpang Internasional yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	1047.0	126.49122	8.28	<.0001	0	t	0
NUM2	-19148.5	5434.3	-3.52	0.0006	0	S2	0
NUM3	-21384.1	5395.0	-3.96	0.0001	0	S3	0
NUM4	24869.8	5297.4	4.69	<.0001	0	S7	0
NUM5	38204.3	5781.0	6.61	<.0001	0	S8	0
NUM6	-40020.6	5761.5	-6.95	<.0001	0	S11	0
NUM7	-31560.7	5837.7	-5.41	<.0001	0	S12	0
NUM8	21904.0	10140.5	2.16	0.0326	0	V2tpl1	0
NUM9	0.23711	0.05684	4.17	<.0001	0	lag1	0
NUM10	0.25013	0.05740	4.36	<.0001	0	lag2	0
NUM11	0.02692	0.04233	0.64	0.5259	0	lag45	0
NUM12	43847.8	18079.2	2.43	0.0167	0	A47	0
NUM13	-158024.5	17844.3	-8.86	<.0001	0	A68	0
NUM14	113779.6	17852.4	6.37	<.0001	0	A178	0
NUM15	61659.5	17453.8	3.53	0.0006	0	A181	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.96536	0.02306	41.86	<.0001	1	Y3_2t	0
AR2,1	-0.25496	0.08970	-2.84	0.0050	46	Y3_2t	0
NUM1	2213.5	287.87178	7.69	<.0001	0	t	0
NUM2	122144.2	16418.5	7.44	<.0001	0	S1	0
NUM3	98883.3	16960.9	5.84	<.0001	0	S2	0
NUM4	103193.1	17441.2	5.92	<.0001	0	S3	0
NUM5	99786.0	17611.7	5.67	<.0001	0	S4	0
NUM6	109386.2	17753.8	6.16	<.0001	0	S5	0
NUM7	117755.7	17880.4	6.59	<.0001	0	S6	0
NUM8	139969.6	17937.5	7.80	<.0001	0	S7	0
NUM9	156064.3	17899.3	8.72	<.0001	0	S8	0
NUM10	140320.5	17888.2	7.84	<.0001	0	S9	0
NUM11	138156.2	17813.0	7.76	<.0001	0	S10	0
NUM12	96306.2	17354.5	5.55	<.0001	0	S11	0
NUM13	95143.9	16903.5	5.63	<.0001	0	S12	0
NUM14	-18119.0	5459.4	-3.32	0.0011	0	V1tmin1	0
NUM15	20530.0	5421.2	3.79	0.0002	0	V3tmin1	0
NUM16	6442.1	5418.4	1.19	0.2362	0	V3tpl1	0
NUM17	-140735.9	17382.0	-8.10	<.0001	0	A68	0
NUM18	145843.0	12755.9	11.43	<.0001	0	A178	0
NUM19	-48990.8	12633.0	-3.88	0.0002	0	A183	0

- Penumpang Internasional yang Datang

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	249.86254	60.83676	4.11	<.0001	0	t	0
NUM2	-10883.2	3670.8	-2.96	0.0035	0	S1	0
NUM3	-8431.7	3637.0	-2.32	0.0217	0	S2	0
NUM4	20999.6	3809.7	5.51	<.0001	0	S6	0
NUM5	28711.3	3972.9	7.23	<.0001	0	S7	0
NUM6	-11405.5	3882.2	-2.94	0.0038	0	S10	0
NUM7	-20752.9	4012.1	-5.17	<.0001	0	S11	0
NUM8	21311.2	4020.2	5.30	<.0001	0	S12	0
NUM9	-21800.3	6148.3	-3.55	0.0005	0	V1tmin1	0
NUM10	-13054.9	6157.4	-2.12	0.0355	0	V1tpl1	0
NUM11	0.78251	0.04362	17.94	<.0001	0	lag1	0
NUM12	0.11200	0.04191	2.67	0.0083	0	lag12	0
NUM13	-88797.1	13847.7	-6.41	<.0001	0	A179	0
NUM14	70498.3	14384.3	4.90	<.0001	0	A180	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.66026	0.07352	8.98	<.0001	1	Y4_2t	0
AR1,2	0.30724	0.07573	4.06	<.0001	2	Y4_2t	0
AR2,1	0.19931	0.09411	2.12	0.0356	10	Y4_2t	0
NUM1	1231.3	368.12519	3.34	0.0010	0	t	0
NUM2	123426.6	14397.9	8.57	<.0001	0	S1	0
NUM3	114635.5	14617.3	7.84	<.0001	0	S2	0
NUM4	122362.8	14798.6	8.27	<.0001	0	S3	0
NUM5	123823.8	15011.3	8.25	<.0001	0	S4	0
NUM6	129097.7	15168.2	8.51	<.0001	0	S5	0
NUM7	150333.9	15274.7	9.84	<.0001	0	S6	0
NUM8	176964.3	15313.5	11.56	<.0001	0	S7	0
NUM9	168319.2	15289.8	11.01	<.0001	0	S8	0
NUM10	158929.7	15228.6	10.44	<.0001	0	S9	0
NUM11	142368.4	15085.3	9.44	<.0001	0	S10	0
NUM12	108860.6	14988.2	7.26	<.0001	0	S11	0
NUM13	137802.4	14832.4	9.29	<.0001	0	S12	0
NUM14	-15134.2	5547.1	-2.73	0.0070	0	V1tmin1	0

- Kargo Domestik yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.23862	0.11464	-2.08	0.0394	0	t	0
NUM2	106.81852	22.06564	4.84	<.0001	0	S3	0
NUM3	115.69144	21.85896	5.29	<.0001	0	S4	0
NUM4	132.72190	22.08889	6.01	<.0001	0	S5	0
NUM5	100.33102	23.26746	4.31	<.0001	0	S6	0
NUM6	115.74263	23.20333	4.99	<.0001	0	S7	0
NUM7	64.55625	25.41683	2.54	0.0123	0	S8	0
NUM8	116.38728	25.69659	4.53	<.0001	0	S9	0
NUM9	151.09757	24.63355	6.13	<.0001	0	S10	0
NUM10	139.42163	23.97089	5.82	<.0001	0	S11	0
NUM11	90.33141	23.29500	3.88	0.0002	0	S12	0
NUM12	-139.36898	40.44553	-3.45	0.0008	0	V1t	0
NUM13	-158.06958	40.39934	-3.91	0.0001	0	V2t	0
NUM14	-95.81658	35.18749	-2.72	0.0074	0	V3t	0
NUM15	-245.45715	48.79185	-5.03	<.0001	0	V4t	0
NUM16	0.73455	0.05514	13.32	<.0001	0	lag1	0
NUM17	0.23033	0.05331	4.32	<.0001	0	lag2	0
NUM18	-0.07491	0.03008	-2.49	0.0141	0	lag26	0
NUM19	552.98481	70.43754	7.85	<.0001	0	A32	0
NUM20	-553.01134	78.41979	-7.05	<.0001	0	A33	0
NUM21	307.86586	67.37681	4.57	<.0001	0	A50	0
NUM22	-218.98401	70.29074	-3.12	0.0023	0	A56	0
NUM23	-197.60792	70.46893	-2.80	0.0059	0	A57	0
NUM24	-156.21489	69.14569	-2.26	0.0256	0	A90	0
NUM25	306.23372	84.80623	3.61	0.0004	0	A128	0
NUM26	468.21428	69.65361	6.72	<.0001	0	A169	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.59014	0.07723	7.64	<.0001	1	Z1_2t	0
AR1,2	0.25828	0.07741	3.34	0.0011	2	Z1_2t	0
NUM1	-1.77699	0.66723	-2.66	0.0085	0	t	0
NUM2	699.88083	64.51977	10.85	<.0001	0	S1	0
NUM3	641.37893	65.57503	9.78	<.0001	0	S2	0
NUM4	676.86077	66.66465	10.15	<.0001	0	S3	0
NUM5	707.67516	67.47565	10.49	<.0001	0	S4	0
NUM6	762.80756	68.12465	11.20	<.0001	0	S5	0
NUM7	760.08517	68.59697	11.08	<.0001	0	S6	0
NUM8	773.70857	68.90457	11.23	<.0001	0	S7	0
NUM9	716.66154	69.30249	10.34	<.0001	0	S8	0
NUM10	713.17300	68.75618	10.37	<.0001	0	S9	0
NUM11	749.37152	68.27073	10.98	<.0001	0	S10	0
NUM12	733.46753	67.46644	10.87	<.0001	0	S11	0
NUM13	769.56283	66.73353	11.53	<.0001	0	S12	0
NUM14	-90.08638	43.48635	-2.07	0.0399	0	V2t	0
NUM15	615.29382	76.67370	8.02	<.0001	0	A32	0
NUM16	-284.83858	77.19443	-3.69	0.0003	0	A168	0

- Kargo Domestik yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.23862	0.11464	-2.08	0.0394	0	t	0
NUM2	106.81852	22.06564	4.84	<.0001	0	S3	0
NUM3	115.69144	21.85896	5.29	<.0001	0	S4	0
NUM4	132.72190	22.08889	6.01	<.0001	0	S5	0
NUM5	100.33102	23.26746	4.31	<.0001	0	S6	0
NUM6	115.74263	23.20333	4.99	<.0001	0	S7	0
NUM7	64.55625	25.41683	2.54	0.0123	0	S8	0
NUM8	116.38728	25.69659	4.53	<.0001	0	S9	0
NUM9	151.09757	24.63355	6.13	<.0001	0	S10	0
NUM10	139.42163	23.97089	5.82	<.0001	0	S11	0
NUM11	90.33141	23.29500	3.88	0.0002	0	S12	0
NUM12	-139.36898	40.44553	-3.45	0.0008	0	V1t	0
NUM13	-158.06958	40.39934	-3.91	0.0001	0	V2t	0
NUM14	-95.81658	35.18749	-2.72	0.0074	0	V3t	0
NUM15	-245.45715	48.79185	-5.03	<.0001	0	V4t	0
NUM16	0.73455	0.05514	13.32	<.0001	0	lag1	0
NUM17	0.23033	0.05331	4.32	<.0001	0	lag2	0
NUM18	-0.07491	0.03008	-2.49	0.0141	0	lag26	0
NUM19	552.98481	70.43754	7.85	<.0001	0	A32	0
NUM20	-553.01134	78.41979	-7.05	<.0001	0	A33	0
NUM21	307.86586	67.37681	4.57	<.0001	0	A50	0
NUM22	-218.98401	70.29074	-3.12	0.0023	0	A56	0
NUM23	-197.60792	70.46893	-2.80	0.0059	0	A57	0
NUM24	-156.21489	69.14569	-2.26	0.0256	0	A90	0
NUM25	306.23372	84.80623	3.61	0.0004	0	A128	0
NUM26	468.21428	69.65361	6.72	<.0001	0	A169	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.45322	0.07845	5.78	<.0001	1	Z2_2t	0
AR1,2	0.33904	0.07894	4.41	<.0001	2	Z2_2t	0
NUM1	5.16796	0.91740	5.63	<.0001	0	t	0
NUM2	660.88763	94.58663	6.99	<.0001	0	S1	0
NUM3	581.56016	95.77439	6.07	<.0001	0	S2	0
NUM4	690.37209	97.22002	7.10	<.0001	0	S3	0
NUM5	683.04852	98.18241	6.96	<.0001	0	S4	0
NUM6	726.65144	98.98104	7.34	<.0001	0	S5	0
NUM7	703.14195	99.55603	7.06	<.0001	0	S6	0
NUM8	729.70946	100.02893	7.29	<.0001	0	S7	0
NUM9	711.09674	100.75425	7.06	<.0001	0	S8	0
NUM10	781.42496	100.48205	7.78	<.0001	0	S9	0
NUM11	834.12735	100.31222	8.32	<.0001	0	S10	0
NUM12	820.17483	97.95192	8.37	<.0001	0	S11	0
NUM13	827.42761	98.52270	8.40	<.0001	0	S12	0
NUM14	-271.19418	77.04588	-3.52	0.0006	0	V2t	0
NUM15	-291.92128	67.99781	-4.29	<.0001	0	V3t	0
NUM16	-173.47579	61.03484	-2.84	0.0050	0	V3tp1	0
NUM17	364.05989	152.28616	2.39	0.0179	0	A12	0
NUM18	322.40238	135.46428	2.38	0.0184	0	A32	0
NUM19	-960.70111	125.53653	-7.65	<.0001	0	A167	0
NUM20	-578.84204	147.74190	-3.92	0.0001	0	A168	0

- Kargo Internasional yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-2.62948	0.74492	-3.53	0.0005	0	t	0
NUM2	648.13198	252.69240	2.56	0.0113	0	S1	0
NUM3	649.85487	238.93991	2.72	0.0073	0	S2	0
NUM4	1273.1	246.99872	5.15	<.0001	0	S3	0
NUM5	1037.3	268.23821	3.87	0.0002	0	S4	0
NUM6	765.46946	272.97201	2.80	0.0057	0	S5	0
NUM7	710.24458	247.87021	2.87	0.0047	0	S6	0
NUM8	839.01542	231.26619	3.63	0.0004	0	S7	0
NUM9	704.39948	253.43992	2.78	0.0061	0	S8	0
NUM10	804.88299	256.70526	3.14	0.0021	0	S9	0
NUM11	1177.4	252.18751	4.67	<.0001	0	S10	0
NUM12	1076.9	254.38817	4.23	<.0001	0	S11	0
NUM13	1080.3	254.48517	4.25	<.0001	0	S12	0
NUM14	-505.46917	136.81755	-3.69	0.0003	0	V1t	0
NUM15	-246.79258	122.58852	-2.01	0.0458	0	V3tp1	0
NUM16	0.54348	0.06327	8.59	<.0001	0	lag1	0
NUM17	0.17129	0.06551	2.61	0.0098	0	lag5	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.59033	0.06278	9.40	<.0001	1	Z3_2t	0
AR1,2	0.18923	0.06696	2.83	0.0053	5	Z3_2t	0
NUM1	-7.66010	1.45054	-5.28	<.0001	0	t	0
NUM2	2766.8	153.42135	18.03	<.0001	0	S1	0
NUM3	2564.5	156.40802	16.40	<.0001	0	S2	0
NUM4	3159.7	158.07957	19.99	<.0001	0	S3	0
NUM5	3228.8	158.96095	20.31	<.0001	0	S4	0
NUM6	3058.5	158.96255	19.24	<.0001	0	S5	0
NUM7	2804.6	159.56594	17.58	<.0001	0	S6	0
NUM8	2762.1	160.17420	17.24	<.0001	0	S7	0
NUM9	2718.9	161.13934	16.87	<.0001	0	S8	0
NUM10	2805.2	162.33554	17.28	<.0001	0	S9	0
NUM11	3163.6	162.19763	19.50	<.0001	0	S10	0
NUM12	3205.7	161.21570	19.88	<.0001	0	S11	0
NUM13	3231.7	158.96661	20.33	<.0001	0	S12	0
NUM14	-418.57501	113.34468	-3.69	0.0003	0	V1t	0
NUM15	-235.50289	130.16559	-1.81	0.0723	0	V2t	0
NUM16	-231.38272	104.77409	-2.21	0.0287	0	V3tp1	0
NUM17	-321.47502	131.57900	-2.44	0.0157	0	V4tp1	0

- Kargo Internasional yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.61206	0.25284	2.42	0.0166	0	t	0
NUM2	-140.26931	40.82629	-3.44	0.0008	0	S1	0
NUM3	-114.15113	43.75865	-2.61	0.0100	0	S2	0
NUM4	120.53858	39.39013	3.06	0.0026	0	S3	0
NUM5	80.34034	42.47367	1.89	0.0604	0	S11	0
NUM6	231.42162	84.03804	2.75	0.0066	0	V4tmin1	0
NUM7	-214.35680	73.13600	-2.93	0.0039	0	V1t	0
NUM8	-181.36828	85.02264	-2.13	0.0345	0	V2t	0
NUM9	-160.58496	65.52044	-2.45	0.0153	0	V3t	0
NUM10	-232.34440	85.52421	-2.72	0.0073	0	V4t	0
NUM11	0.80154	0.05032	15.93	<.0001	0	lag1	0
NUM12	0.14221	0.05179	2.75	0.0067	0	lag2	0
NUM13	493.98363	149.55738	3.30	0.0012	0	A86	0
NUM14	1331.0	145.99282	9.12	<.0001	0	A108	0
NUM15	-1330.3	160.70963	-8.28	<.0001	0	A110	0
NUM16	-620.81798	145.20671	-4.28	<.0001	0	A149	0
NUM17	-741.95790	150.53660	-4.93	<.0001	0	A167	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.74319	0.06397	11.62	<.0001	1	Z4_2t	0
AR1,2	0.13840	0.06421	2.16	0.0327	3	Z4_2t	0
NUM1	2.75636	1.32639	2.08	0.0394	0	t	0
NUM2	504.96097	119.75524	4.22	<.0001	0	S1	0
NUM3	429.13503	122.94406	3.49	0.0006	0	S2	0
NUM4	593.74839	124.36830	4.77	<.0001	0	S3	0
NUM5	618.58985	125.84660	4.92	<.0001	0	S4	0
NUM6	593.08835	127.37522	4.66	<.0001	0	S5	0
NUM7	608.71402	128.08083	4.75	<.0001	0	S6	0
NUM8	628.62472	128.70548	4.88	<.0001	0	S7	0
NUM9	609.29145	129.02299	4.72	<.0001	0	S8	0
NUM10	599.40850	128.47317	4.67	<.0001	0	S9	0
NUM11	620.08287	127.99424	4.84	<.0001	0	S10	0
NUM12	662.13143	125.81290	5.26	<.0001	0	S11	0
NUM13	659.19288	123.89570	5.32	<.0001	0	S12	0
NUM14	232.27486	67.49533	3.44	0.0007	0	V4tmin1	0
NUM15	-137.92680	58.24433	-2.37	0.0191	0	V1t	0
NUM16	-134.58497	52.13710	-2.58	0.0108	0	V3t	0
NUM17	387.56869	118.17102	3.28	0.0013	0	A17	0
NUM18	413.94095	118.55979	3.49	0.0006	0	A86	0
NUM19	1398.5	136.73749	10.23	<.0001	0	A108	0
NUM20	1310.2	135.09442	9.70	<.0001	0	A109	0
NUM21	273.43472	118.67056	2.30	0.0226	0	A159	0
NUM22	-669.82654	138.35516	-4.84	<.0001	0	A167	0

C. Bandara Juanda

- Penumpang Domestik yang Berangkat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	309.37191	155.56689	1.99	0.0485	0	t	0
NUM2	-33581.3	8926.8	-3.76	0.0002	0	S2	0
NUM3	24837.2	8160.4	3.04	0.0028	0	S5	0
NUM4	42579.3	8384.3	5.08	<.0001	0	S7	0
NUM5	-58463.4	15251.4	-3.83	0.0002	0	V1tmin1	0
NUM6	-48898.5	17234.9	-2.84	0.0052	0	V2tmin1	0
NUM7	82002.1	14075.7	5.83	<.0001	0	V1t	0
NUM8	46267.5	17673.5	2.62	0.0097	0	V2t	0
NUM9	-129212.9	22484.5	-5.75	<.0001	0	V4t	0
NUM10	31185.4	14618.9	2.13	0.0345	0	V1tpl1	0
NUM11	53669.0	13696.1	3.92	0.0001	0	V3tpl1	0
NUM12	79814.9	21303.2	3.75	0.0003	0	V4tpl1	0
NUM13	0.46437	0.05141	9.03	<.0001	0	lag1	0
NUM14	0.35426	0.04820	7.35	<.0001	0	lag2	0
NUM15	-0.14057	0.05399	-2.60	0.0101	0	lag10	0
NUM16	0.25288	0.05944	4.25	<.0001	0	lag12	0
NUM17	87088.7	29337.2	2.97	0.0035	0	A30	0
NUM18	107898.4	36537.4	2.95	0.0036	0	A35	0
NUM19	-80192.0	33803.0	-2.37	0.0189	0	A151	0
NUM20	-96480.3	30378.9	-3.18	0.0018	0	A158	0
NUM21	114856.0	36993.2	3.10	0.0023	0	A164	0
NUM22	-77227.6	29745.1	-2.60	0.0103	0	A169	0
NUM23	-84082.0	30722.2	-2.74	0.0069	0	A170	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.44625	0.07563	5.90	<.0001	1	Y1_3t	0
AR1,2	0.39884	0.07302	5.46	<.0001	2	Y1_3t	0
AR2,1	0.68685	0.08320	8.26	<.0001	12	Y1_3t	0
AR2,2	-0.32570	0.09299	-3.50	0.0006	24	Y1_3t	0
NUM1	3868.6	213.01988	18.16	<.0001	0	t	0
NUM2	-33313.7	11033.9	-3.02	0.0029	0	S2	0
NUM3	29977.5	11121.2	2.70	0.0077	0	S7	0
NUM4	-66526.7	12558.8	-5.30	<.0001	0	V1tmin1	0
NUM5	-61924.2	14824.3	-4.18	<.0001	0	V2tmin1	0
NUM6	-77870.6	15159.3	-5.14	<.0001	0	V4t	0
NUM7	65339.0	23234.5	2.81	0.0055	0	A126	0
NUM8	66490.2	23443.8	2.84	0.0051	0	A164	0

- Penumpang Domestik yang Datang

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	307.98207	146.24290	2.11	0.0367	0	t	0
NUM2	-45631.5	9874.1	-4.62	<.0001	0	S2	0
NUM3	25542.4	10038.3	2.54	0.0119	0	S5	0
NUM4	38877.6	9115.6	4.26	<.0001	0	S6	0
NUM5	58045.4	9394.2	6.18	<.0001	0	S7	0
NUM6	21990.6	9401.3	2.34	0.0205	0	S11	0
NUM7	33443.5	9427.4	3.55	0.0005	0	S12	0
NUM8	-75227.1	15337.5	-4.90	<.0001	0	V1tmin1	0
NUM9	-41132.6	19531.5	-2.11	0.0367	0	V2tmin1	0
NUM10	-40424.0	19843.2	-2.04	0.0432	0	V4t	0
NUM11	0.26621	0.05450	4.88	<.0001	0	lag1	0
NUM12	0.46472	0.05526	8.41	<.0001	0	lag2	0
NUM13	0.20812	0.05117	4.07	<.0001	0	lag5	0
NUM14	113520.6	35052.9	3.24	0.0014	0	A41	0
NUM15	-111596.2	34526.7	-3.23	0.0015	0	A158	0
NUM16	-134169.3	35448.4	-3.78	0.0002	0	A170	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.89135	0.03694	24.13	<.0001	1	Y2_3t	0
AR2,1	0.47541	0.08022	5.93	<.0001	12	Y2_3t	0
NUM1	4366.7	302.80008	14.42	<.0001	0	t	0
NUM2	53291.6	11550.3	4.61	<.0001	0	S1	0
NUM3	38557.8	12282.4	3.14	0.0020	0	S5	0
NUM4	33931.0	15188.4	2.23	0.0268	0	S6	0
NUM5	66835.3	15150.3	4.41	<.0001	0	S7	0
NUM6	32914.6	12592.3	2.61	0.0098	0	S8	0
NUM7	32410.4	12642.2	2.56	0.0113	0	S10	0
NUM8	42674.1	15063.8	2.83	0.0052	0	S11	0
NUM9	72947.2	15158.7	4.81	<.0001	0	S12	0
NUM10	-76963.0	10198.4	-7.55	<.0001	0	V1tmin1	0
NUM11	-44116.4	12014.1	-3.67	0.0003	0	V2tmin1	0
NUM12	-63221.9	13640.8	-4.63	<.0001	0	V4t	0
NUM13	-53935.2	9898.1	-5.45	<.0001	0	V1tpl1	0
NUM14	-34978.8	9877.4	-3.54	0.0005	0	V3tpl1	0
NUM15	-46875.5	21340.8	-2.20	0.0295	0	A36	0
NUM16	-72556.3	21038.2	-3.45	0.0007	0	A70	0
NUM17	-83278.2	20638.5	-4.04	<.0001	0	A96	0
NUM18	-47155.8	21038.4	-2.24	0.0263	0	A105	0
NUM19	89079.6	21458.8	4.15	<.0001	0	A129	0
NUM20	64795.2	22563.8	2.87	0.0046	0	A150	0
NUM21	53991.1	22926.4	2.35	0.0197	0	A162	0
NUM22	95475.6	22908.8	4.17	<.0001	0	A168	0
NUM23	101507.9	26007.3	3.90	0.0001	0	A180	0

- Penumpang Internasional yang Datang

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	190.34472	15.21947	12.51	<.0001	0	t	0
NUM2	6504.4	1202.6	5.41	<.0001	0	S3	0
NUM3	2062.4	1184.9	1.74	0.0839	0	S4	0
NUM4	3764.7	1192.3	3.16	0.0019	0	S5	0
NUM5	7869.3	1247.7	6.31	<.0001	0	S6	0
NUM6	3705.6	1220.7	3.04	0.0028	0	S7	0
NUM7	7682.0	1328.0	5.78	<.0001	0	S8	0
NUM8	6798.9	1335.8	5.09	<.0001	0	S9	0
NUM9	5781.4	1420.7	4.07	<.0001	0	S10	0
NUM10	4563.5	1345.7	3.39	0.0009	0	S11	0
NUM11	10185.8	1612.6	6.32	<.0001	0	S12	0
NUM12	-5069.0	1982.1	-2.56	0.0116	0	V1tmin1	0
NUM13	-9325.7	2529.4	-3.69	0.0003	0	V2tmin1	0
NUM14	-6098.1	2176.6	-2.80	0.0058	0	V3tmin1	0
NUM15	7720.4	2198.2	3.51	0.0006	0	V1t	0
NUM16	6667.3	2559.2	2.61	0.0101	0	V2t	0
NUM17	18272.2	3083.0	5.93	<.0001	0	V2tpl1	0
NUM18	9669.7	2250.8	4.30	<.0001	0	V3tpl1	0
NUM19	8966.1	2601.6	3.45	0.0007	0	V4tpl1	0
NUM20	0.30370	0.03780	8.03	<.0001	0	lag1	0
NUM21	0.16204	0.04476	3.62	0.0004	0	lag12	0
NUM22	28287.7	4808.3	5.88	<.0001	0	A13	0
NUM23	22055.8	4475.5	4.93	<.0001	0	A25	0
NUM24	40379.9	4301.2	9.39	<.0001	0	A37	0
NUM25	32529.9	4369.1	7.45	<.0001	0	A72	0
NUM26	18152.7	4444.6	4.08	<.0001	0	A84	0
NUM27	-21727.2	5316.2	-4.09	<.0001	0	A118	0
NUM28	18101.2	4224.6	4.28	<.0001	0	A145	0
NUM29	22216.4	4843.9	4.59	<.0001	0	A152	0
NUM30	18924.8	4383.6	4.32	<.0001	0	A156	0
NUM31	27281.8	4403.9	6.19	<.0001	0	A166	0
NUM32	-29776.4	4444.1	-6.70	<.0001	0	A188	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.29121	0.08435	3.45	0.0007	1	Y3_3t	0
AR2,1	0.50398	0.08444	5.97	<.0001	12	Y3_3t	0
NUM1	255.11329	21.05167	12.12	<.0001	0	t	0
NUM2	22054.9	3068.3	7.19	<.0001	0	S1	0
NUM3	15677.7	3185.6	4.92	<.0001	0	S2	0
NUM4	17702.6	3058.3	5.79	<.0001	0	S3	0
NUM5	13854.3	3070.2	4.51	<.0001	0	S4	0
NUM6	14254.1	3078.4	4.63	<.0001	0	S5	0
NUM7	17571.1	3089.8	5.69	<.0001	0	S6	0
NUM8	15903.2	3103.0	5.13	<.0001	0	S7	0
NUM9	18232.5	3143.3	5.80	<.0001	0	S8	0
NUM10	19403.7	3160.3	6.14	<.0001	0	S9	0
NUM11	18917.1	3154.8	6.00	<.0001	0	S10	0
NUM12	20170.4	3154.8	6.39	<.0001	0	S11	0
NUM13	29348.0	3165.3	9.27	<.0001	0	S12	0
NUM14	-16039.1	3146.8	-5.10	<.0001	0	V1tpl1	0
NUM15	36456.7	5122.2	7.12	<.0001	0	A2	0
NUM16	20991.5	5587.1	3.76	0.0002	0	A13	0
NUM17	32357.7	6683.3	4.84	<.0001	0	A25	0
NUM18	38498.7	5401.1	7.13	<.0001	0	A37	0
NUM19	9843.3	4726.5	2.08	0.0389	0	A44	0
NUM20	22585.8	5296.9	4.26	<.0001	0	A84	0
NUM21	24546.5	5582.6	4.40	<.0001	0	A72	0
NUM22	8795.7	2495.0	3.53	0.0006	0	A145	0
NUM23	21121.3	4970.9	4.25	<.0001	0	A152	0
NUM24	27454.8	5835.7	4.70	<.0001	0	A153	0
NUM25	11257.9	4809.1	2.34	0.0205	0	A156	0
NUM26	25062.9	4802.5	5.22	<.0001	0	A166	0

- Penumpang Internasional yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	180.58360	26.95750	6.70	<.0001	0	t	0
NUM2	16348.5	1983.4	8.24	<.0001	0	S1	0
NUM3	9105.7	1814.6	5.02	<.0001	0	S3	0
NUM4	7087.6	1784.6	3.97	0.0001	0	S4	0
NUM5	10209.8	1798.0	5.68	<.0001	0	S5	0
NUM6	9179.6	1902.7	4.82	<.0001	0	S6	0
NUM7	14831.8	1886.3	7.86	<.0001	0	S7	0
NUM8	11389.5	1916.9	5.94	<.0001	0	S8	0
NUM9	9730.3	1876.8	5.18	<.0001	0	S9	0
NUM10	10284.8	1918.5	5.36	<.0001	0	S10	0
NUM11	12942.1	2108.4	6.14	<.0001	0	S11	0
NUM12	12809.8	2109.1	6.07	<.0001	0	S12	0
NUM13	-5759.8	2920.9	-1.97	0.0509	0	V1tpl1	0
NUM14	-8099.0	2928.2	-2.77	0.0066	0	V3tpl1	0
NUM15	0.08889	0.04467	1.99	0.0488	0	lag1	0
NUM16	0.41085	0.05572	7.37	<.0001	0	lag35	0
NUM17	25243.3	5847.4	4.32	<.0001	0	A38	0
NUM18	20356.9	6083.9	3.35	0.0011	0	A50	0
NUM19	24026.8	5765.8	4.17	<.0001	0	A96	0
NUM20	21100.8	5879.7	3.59	0.0005	0	A108	0
NUM21	18830.5	5989.5	3.14	0.0021	0	A143	0
NUM22	21912.9	5789.6	3.78	0.0002	0	A145	0
NUM23	13193.7	5693.3	2.32	0.0221	0	A147	0
NUM24	14816.9	5688.1	2.60	0.0103	0	A150	0
NUM25	20291.6	5718.9	3.55	0.0006	0	A151	0
NUM26	16300.9	5771.8	2.82	0.0055	0	A152	0
NUM27	16852.8	5793.0	2.91	0.0043	0	A155	0
NUM28	16080.4	5745.0	2.80	0.0060	0	A157	0
NUM29	-18976.7	5860.8	-3.24	0.0015	0	A167	0
NUM30	-14982.2	5928.0	-2.53	0.0128	0	A180	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.35967	0.07562	4.76	<.0001	1	Y4_3t	0
AR2,1	0.52587	0.06688	7.86	<.0001	12	Y4_3t	0
AR2,2	-0.35001	0.07600	-4.61	<.0001	36	Y4_3t	0
NUM1	251.26717	28.22462	8.90	<.0001	0	t	0
NUM2	13019.1	2486.6	5.24	<.0001	0	S1	0
NUM3	5651.3	2272.8	2.49	0.0138	0	S7	0
NUM4	5488.8	2551.9	2.15	0.0329	0	S11	0
NUM5	8821.7	2702.2	3.26	0.0013	0	S12	0
NUM6	-6710.9	2916.2	-2.30	0.0226	0	V3tpl1	0
NUM7	20343.5	2466.7	8.25	<.0001	0	A3	0
NUM8	28490.2	6141.6	4.64	<.0001	0	A15	0
NUM9	22125.1	6600.8	3.35	0.0010	0	A38	0
NUM10	24722.4	6683.0	3.70	0.0003	0	A50	0
NUM11	-20195.7	6254.1	-3.23	0.0015	0	A61	0
NUM12	10686.1	3615.2	2.96	0.0036	0	A143	0

- Kargo Domestik yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	9.41834	1.59072	5.92	<.0001	0	t	0
NUM2	234.56303	112.28118	2.09	0.0387	0	S1	0
NUM3	351.06049	111.12561	3.16	0.0020	0	S3	0
NUM4	333.91688	108.61400	3.07	0.0026	0	S4	0
NUM5	404.72630	107.35559	3.77	0.0002	0	S5	0
NUM6	270.77752	107.66935	2.51	0.0132	0	S6	0
NUM7	292.73183	113.54808	2.58	0.0111	0	S7	0
NUM8	719.48047	106.82540	6.74	<.0001	0	S10	0
NUM9	391.52609	107.71381	3.63	0.0004	0	S11	0
NUM10	674.93600	108.17740	6.24	<.0001	0	S12	0
NUM11	-353.33525	172.87070	-2.04	0.0430	0	V1t	0
NUM12	0.69539	0.04225	16.46	<.0001	0	lag1	0
NUM13	-0.20513	0.04648	-4.41	<.0001	0	lag45	0
NUM14	1115.3	349.96725	3.19	0.0018	0	A55	0
NUM15	-853.63855	347.19007	-2.46	0.0153	0	A63	0
NUM16	858.37241	338.32182	2.54	0.0124	0	A105	0
NUM17	-964.99932	337.77528	-2.86	0.0050	0	A153	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.86616	0.03958	21.88	<.0001	1	Z1_3t	0
NUM1	18.45921	2.51206	7.35	<.0001	0	t	0
NUM2	1141.6	254.57748	4.48	<.0001	0	S1	0
NUM3	718.93894	261.62132	2.75	0.0067	0	S2	0
NUM4	749.83008	266.96135	2.81	0.0056	0	S3	0
NUM5	775.28276	271.06178	2.86	0.0048	0	S4	0
NUM6	847.32971	274.46882	3.09	0.0024	0	S5	0
NUM7	874.95812	276.13756	3.17	0.0018	0	S6	0
NUM8	1011.9	277.22050	3.65	0.0004	0	S7	0
NUM9	983.67992	278.16845	3.54	0.0005	0	S8	0
NUM10	735.75977	276.25440	2.66	0.0085	0	S9	0
NUM11	1048.5	272.70035	3.84	0.0002	0	S10	0
NUM12	1141.9	269.00575	4.25	<.0001	0	S11	0
NUM13	1425.6	263.24803	5.42	<.0001	0	S12	0
NUM14	-534.78336	137.43165	-3.89	0.0001	0	V1t	0
NUM15	-421.16888	134.29383	-3.14	0.0020	0	V3t	0
NUM16	-642.43559	146.15286	-4.40	<.0001	0	V1tpl1	0
NUM17	-375.21190	134.75129	-2.78	0.0060	0	V3tpl1	0
NUM18	-534.30586	264.02421	-2.02	0.0446	0	A93	0
NUM19	-949.34578	267.13446	-3.55	0.0005	0	A96	0
NUM20	-1186.9	264.68782	-4.48	<.0001	0	A104	0
NUM21	-858.91776	264.64380	-3.25	0.0014	0	A107	0
NUM22	582.69079	253.77674	2.30	0.0229	0	A149	0

- Kargo Domestik yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	2.28941	0.89972	2.54	0.0120	0	t	0
NUM2	960.56721	231.85994	4.14	<.0001	0	S1	0
NUM3	720.57950	227.00277	3.17	0.0019	0	S2	0
NUM4	1085.3	221.51325	4.90	<.0001	0	S3	0
NUM5	814.02598	221.39044	3.68	0.0003	0	S4	0
NUM6	1162.0	220.98347	5.26	<.0001	0	S5	0
NUM7	979.04039	227.93629	4.30	<.0001	0	S6	0
NUM8	1121.1	226.29270	4.95	<.0001	0	S7	0
NUM9	916.10591	234.32220	3.91	0.0001	0	S8	0
NUM10	1148.2	220.86982	5.20	<.0001	0	S9	0
NUM11	972.67912	222.48112	4.37	<.0001	0	S10	0
NUM12	1025.6	218.35256	4.70	<.0001	0	S11	0
NUM13	1219.1	216.25505	5.64	<.0001	0	S12	0
NUM14	-367.30824	208.01450	-1.77	0.0797	0	V3min1	0
NUM15	-495.87771	206.55021	-2.40	0.0177	0	V1t	0
NUM16	0.64932	0.06022	10.78	<.0001	0	lag1	0
NUM17	0.23201	0.08028	2.89	0.0045	0	lag21	0
NUM18	-0.25856	0.08286	-3.12	0.0022	0	lag22	0
NUM19	-0.16097	0.06141	-2.62	0.0097	0	lag32	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.46208	0.06949	6.65	<.0001	1	Z2_3t	0
AR1,2	0.45307	0.06972	6.50	<.0001	2	Z2_3t	0
AR1,3	-0.10246	0.03985	-2.57	0.0110	22	Z2_3t	0
NUM1	9.03000	1.95944	4.61	<.0001	0	t	0
NUM2	1315.4	200.10968	6.57	<.0001	0	S1	0
NUM3	1110.2	202.56313	5.48	<.0001	0	S2	0
NUM4	1240.1	205.00861	6.05	<.0001	0	S3	0
NUM5	1104.7	207.35584	5.33	<.0001	0	S4	0
NUM6	1218.6	208.75373	5.84	<.0001	0	S5	0
NUM7	1215.1	209.72930	5.79	<.0001	0	S6	0
NUM8	1297.5	210.45307	6.17	<.0001	0	S7	0
NUM9	1201.1	210.28185	5.71	<.0001	0	S8	0
NUM10	1362.0	210.01673	6.49	<.0001	0	S9	0
NUM11	1271.7	210.50387	6.04	<.0001	0	S10	0
NUM12	1286.9	207.22228	6.21	<.0001	0	S11	0
NUM13	1461.3	206.93525	7.06	<.0001	0	S12	0
NUM14	-295.65339	114.81795	-2.57	0.0109	0	V1t	0
NUM15	576.31364	271.37632	2.12	0.0352	0	A38	0
NUM16	942.59647	297.37327	3.17	0.0018	0	A40	0
NUM17	1131.2	268.13220	4.22	<.0001	0	A41	0
NUM18	1129.9	280.10272	4.03	<.0001	0	A42	0
NUM19	1009.3	257.53175	3.92	0.0001	0	A61	0
NUM20	872.70250	255.79723	3.41	0.0008	0	A82	0
NUM21	1080.5	254.79495	4.24	<.0001	0	A108	0
NUM22	1433.1	254.94435	5.62	<.0001	0	A115	0

- Kargo Internasional yang Dimuat

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.43784	0.18921	2.31	0.0219	0	t	0
NUM2	109.50007	30.14175	3.63	0.0004	0	S3	0
NUM3	81.35496	28.94838	2.81	0.0055	0	S6	0
NUM4	69.70292	29.24207	2.38	0.0182	0	S7	0
NUM5	59.90863	29.60984	2.02	0.0446	0	S9	0
NUM6	86.16164	29.66762	2.90	0.0042	0	S10	0
NUM7	71.23621	29.94364	2.38	0.0185	0	S11	0
NUM8	67.32458	30.05709	2.24	0.0264	0	S12	0
NUM9	0.64944	0.05471	11.87	<.0001	0	lag1	0
NUM10	0.21252	0.05494	3.87	0.0002	0	lag5	0
NUM11	228.76641	108.33496	2.11	0.0362	0	A16	0
NUM12	227.73198	108.07711	2.11	0.0366	0	A100	0
NUM13	-290.55218	108.30162	-2.68	0.0080	0	A140	0

Model ARIMAX

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.60469	0.07493	8.07	<.0001	1	Z3_3t	0
AR1,2	0.19011	0.07621	2.49	0.0136	2	Z3_3t	0
NUM1	1.33692	0.63040	2.12	0.0354	0	t	0
NUM2	555.51976	68.93831	8.06	<.0001	0	S1	0
NUM3	460.58148	70.09278	6.57	<.0001	0	S2	0
NUM4	558.49674	71.14717	7.85	<.0001	0	S3	0
NUM5	519.40163	71.95814	7.22	<.0001	0	S4	0
NUM6	523.46451	72.60024	7.21	<.0001	0	S5	0
NUM7	562.51832	73.08419	7.70	<.0001	0	S6	0
NUM8	556.75787	73.41890	7.58	<.0001	0	S7	0
NUM9	522.57689	73.60133	7.10	<.0001	0	S8	0
NUM10	530.01375	73.16574	7.24	<.0001	0	S9	0
NUM11	566.51308	72.68631	7.79	<.0001	0	S10	0
NUM12	584.59356	71.90838	8.13	<.0001	0	S11	0
NUM13	596.19432	71.05689	8.39	<.0001	0	S12	0

- Kargo Internasional yang Dibongkar

Model TSR

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.43784	0.18921	2.31	0.0219	0	t	0
NUM2	109.50007	30.14175	3.63	0.0004	0	S3	0
NUM3	81.35496	28.94838	2.81	0.0055	0	S6	0
NUM4	69.70292	29.24207	2.38	0.0182	0	S7	0
NUM5	59.90863	29.60984	2.02	0.0446	0	S9	0
NUM6	86.16164	29.66762	2.90	0.0042	0	S10	0
NUM7	71.23621	29.94364	2.38	0.0185	0	S11	0
NUM8	67.32458	30.05709	2.24	0.0264	0	S12	0
NUM9	0.64944	0.05471	11.87	<.0001	0	lag1	0
NUM10	0.21252	0.05494	3.87	0.0002	0	lag5	0
NUM11	228.76641	108.33496	2.11	0.0362	0	A16	0
NUM12	227.73198	108.07711	2.11	0.0366	0	A100	0
NUM13	-290.55218	108.30162	-2.68	0.0080	0	A140	0

Model ARIMAX



Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1,1	0.55457	0.06456	8.59	<.0001	1	Z4_3t	0
NUM1	3.10009	0.44202	7.01	<.0001	0	t	0
NUM2	340.87688	59.53682	5.73	<.0001	0	S1	0
NUM3	229.98011	60.42621	3.81	0.0002	0	S2	0
NUM4	391.29593	60.96828	6.42	<.0001	0	S3	0
NUM5	336.14341	61.37468	5.48	<.0001	0	S4	0
NUM6	426.16950	61.72073	6.90	<.0001	0	S5	0
NUM7	425.39537	62.18855	6.84	<.0001	0	S6	0
NUM8	401.86437	62.58014	6.42	<.0001	0	S7	0
NUM9	338.25651	62.67534	5.40	<.0001	0	S8	0
NUM10	312.12421	62.82534	4.97	<.0001	0	S9	0
NUM11	397.60130	62.88056	6.32	<.0001	0	S10	0
NUM12	392.78832	62.27360	6.31	<.0001	0	S11	0
NUM13	402.37071	62.26964	6.46	<.0001	0	S12	0
NUM14	234.81417	78.03066	3.01	0.0030	0	V4tmin1	0
NUM15	-225.33909	60.07942	-3.75	0.0002	0	V3t	0
NUM16	984.79926	137.29837	7.17	<.0001	0	A108	0

Lampiran 10. Arsitektur FFNN Terbaik *Hybrid* TSR-NN dan ARIMAX-NN

A. Bandara Soekarno Hatta



- Penumpang Domestik yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	4.31	6.80	ARIMAX	6.39	4.88
TSR-NN (4,1,1)	3.79	6.83	ARIMAX-NN (4,1,1)	5.12	5.11
TSR-NN (4,2,1)	3.69	6.95	ARIMAX-NN (4,2,1)	5.10	5.24
TSR-NN (4,2,1)	3.45	7.34	ARIMAX-NN (4,2,1)	4.73	5.52
TSR-NN (4,4,1)	3.53	7.34	ARIMAX-NN (4,4,1)	5.00	5.49
TSR-NN (4,5,1)	3.40	7.81	ARIMAX-NN (4,4,1)	4.55	5.42
TSR-NN (4,6,1)	3.13	7.98	ARIMAX-NN (4,6,1)	4.55	6.16
TSR-NN (4,7,1)	3.11	6.63	ARIMAX-NN (4,7,1)	4.35	5.73
TSR-NN (4,8,1)	2.76	7.85	ARIMAX-NN (4,8,1)	4.06	4.39
TSR-NN (4,9,1)	2.65	6.92	ARIMAX-NN (4,9,1)	3.56	4.11
TSR-NN (4,10,1)	2.46	5.77	ARIMAX-NN (4,10,1)	3.56	7.54




- Penumpang Domestik yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	5.78	6.39	ARIMAX	7.43	5.16
TSR-NN (2,1,1)	4.84	5.82	ARIMAX-NN (2,1,1)	6.11	5.46
TSR-NN (2,2,1)	4.90	5.69	ARIMAX-NN (2,2,1)	6.00	5.17
TSR-NN (2,2,1)	4.64	5.65	ARIMAX-NN (2,2,1)	5.58	5.82
TSR-NN (2,4,1)	4.72	6.37	ARIMAX-NN (2,4,1)	5.73	5.89
TSR-NN (2,5,1)	4.42	6.24	ARIMAX-NN (2,5,1)	5.26	4.97
TSR-NN (2,6,1)	4.13	6.78	ARIMAX-NN (2,6,1)	5.18	5.72
TSR-NN (2,7,1)	3.88	6.47	ARIMAX-NN (2,7,1)	5.04	5.56
TSR-NN (2,8,1)	3.81	5.80	ARIMAX-NN (2,8,1)	4.96	6.61
TSR-NN (2,9,1)	3.61	5.51	ARIMAX-NN (2,9,1)	4.76	6.46
TSR-NN (2,10,1)	3.35	5.75	ARIMAX-NN (2,10,1)	4.48	6.01




- Penumpang Internasional yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	6.26	4.99	ARIMAX	5.15	5.13
TSR-NN (3,1,1)	5.84	4.98	ARIMAX-NN (2,1,1)	4.93	5.16
TSR-NN (3,2,1)	5.66	4.89	ARIMAX-NN (2,2,1)	4.78	5.27
TSR-NN (3,3,1)	5.63	5.02	ARIMAX-NN (2,2,1)	4.88	5.40
TSR-NN (3,4,1)	5.42	4.41	ARIMAX-NN (2,4,1)	4.43	5.08
TSR-NN (3,5,1)	4.75	10.62	ARIMAX-NN (2,2,1)	4.84	5.47
TSR-NN (3,6,1)	4.69	5.32	ARIMAX-NN (2,6,1)	4.61	5.03
TSR-NN (3,7,1)	4.85	5.25	ARIMAX-NN (2,7,1)	4.52	4.86
TSR-NN (3,8,1)	4.31	6.68	ARIMAX-NN (2,8,1)	3.98	5.35
TSR-NN (3,9,1)	4.15	7.66	ARIMAX-NN (2,9,1)	3.90	4.92
TSR-NN (3,10,1)	3.86	7.18	ARIMAX-NN (2,10,1)	4.14	4.88





- Penumpang Internasional yang Datang

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	9.79	7.22	ARIMAX	6.53	9.14
TSR-NN (4,1,1)	6.17	6.86	ARIMAX-NN (5,1,1)	6.12	8.81
TSR-NN (4,2,1)	5.98	7.43	ARIMAX-NN (5,2,1)	5.85	9.00
TSR-NN (4,2,1)	5.76	8.45	ARIMAX-NN (5,2,1)	5.78	8.97
TSR-NN (4,4,1)	5.01	7.77	ARIMAX-NN (5,4,1)	4.93	7.31
TSR-NN (4,5,1)	4.99	7.73	ARIMAX-NN (5,5,1)	4.55	9.18
TSR-NN (4,6,1)	4.79	7.55	ARIMAX-NN (5,5,1)	4.17	11.12
TSR-NN (4,7,1)	4.57	7.77	ARIMAX-NN (5,7,1)	4.09	8.36
TSR-NN (4,8,1)	4.81	8.33	ARIMAX-NN (5,8,1)	3.67	8.11
TSR-NN (4,9,1)	3.70	7.02	ARIMAX-NN (5,9,1)	3.19	9.78
TSR-NN (4,10,1)	3.37	7.60	ARIMAX-NN (5,10,1)	3.27	8.26





- Kargo Domestik yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	6.47	11.54	ARIMAX	6.42	10.66
TSR-NN (2,1,1)	6.35	11.49	ARIMAX-NN (2,1,1)	6.08	10.91
TSR-NN (2,2,1)	6.42	11.28	ARIMAX-NN (2,2,1)	5.77	10.44
TSR-NN (2,3,1)	6.10	11.24	ARIMAX-NN (2,3,1)	6.01	10.91
TSR-NN (2,4,1)	6.10	11.13	ARIMAX-NN (2,4,1)	5.53	11.62
TSR-NN (2,5,1)	5.76	11.22	ARIMAX-NN (2,5,1)	5.70	11.12
TSR-NN (2,6,1)	6.22	10.96	ARIMAX-NN (2,6,1)	5.44	11.80
TSR-NN (2,7,1)	5.79	10.52	ARIMAX-NN (2,7,1)	5.48	11.31
TSR-NN (2,8,1)	5.21	11.69	ARIMAX-NN (2,8,1)	5.31	12.76
TSR-NN (2,9,1)	5.58	11.60	ARIMAX-NN (2,9,1)	5.12	11.62
TSR-NN (2,10,1)	5.56	10.57	ARIMAX-NN (2,10,1)	4.77	10.88




- Kargo Domestik yang Dibongkar

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	7.47	28.77	ARIMAX	6.90	29.76
TSR-NN (2,1,1)	6.94	30.02	ARIMAX-NN (2,1,1)	6.55	30.27
TSR-NN (2,2,1)	6.95	28.41	ARIMAX-NN (2,2,1)	6.39	29.94
TSR-NN (2,2,1)	6.43	31.49	ARIMAX-NN (2,2,1)	6.27	29.45
TSR-NN (2,4,1)	6.33	30.69	ARIMAX-NN (2,4,1)	5.89	31.80
TSR-NN (2,5,1)	6.02	29.84	ARIMAX-NN (2,5,1)	5.67	28.51
TSR-NN (2,6,1)	6.09	31.82	ARIMAX-NN (2,6,1)	5.75	34.75
TSR-NN (2,7,1)	5.95	30.22	ARIMAX-NN (2,7,1)	5.32	32.63
TSR-NN (2,8,1)	5.96	31.06	ARIMAX-NN (2,8,1)	5.24	30.21
TSR-NN (2,9,1)	5.55	32.01	ARIMAX-NN (2,9,1)	4.87	24.13
TSR-NN (2,10,1)	5.39	31.05	ARIMAX-NN (2,10,1)	5.20	30.61




- Kargo Internasional yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	10.66	10.51	ARIMAX	11.05	12.01
TSR-NN (2,1,1)	10.11	11.24	ARIMAX-NN (2,1,1)	10.48	12.50
TSR-NN (2,2,1)	10.18	11.08	ARIMAX-NN (2,2,1)	10.92	11.67
TSR-NN (2,2,1)	9.95	12.31	ARIMAX-NN (2,3,1)	9.97	11.90
TSR-NN (2,2,1)	9.38	12.47	ARIMAX-NN (2,4,1)	9.64	11.41
TSR-NN (2,5,1)	9.72	11.67	ARIMAX-NN (2,5,1)	9.48	11.33
TSR-NN (2,6,1)	9.55	10.49	ARIMAX-NN (2,6,1)	9.31	12.33
TSR-NN (2,7,1)	9.26	11.15	ARIMAX-NN (2,7,1)	9.31	11.75
TSR-NN (2,8,1)	9.13	12.33	ARIMAX-NN (2,8,1)	9.25	14.30
TSR-NN (2,9,1)	8.84	14.26	ARIMAX-NN (2,9,1)	8.21	13.74
TSR-NN (2,10,1)	8.37	10.72	ARIMAX-NN (2,10,1)	8.85	11.74




- Kargo Internasional yang Dibongkar

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	12.43	16.20	ARIMAX	14.38	19.68
TSR-NN (1,1,1)	12.33	16.25	ARIMAX-NN (3,1,1)	14.21	19.60
TSR-NN (1,2,1)	12.35	16.28	ARIMAX-NN (3,2,1)	13.68	19.84
TSR-NN (1,2,1)	12.32	16.25	ARIMAX-NN (3,3,1)	12.57	20.07
TSR-NN (1,4,1)	12.35	16.31	ARIMAX-NN (3,4,1)	12.26	20.38
TSR-NN (1,5,1)	12.16	16.25	ARIMAX-NN (3,5,1)	11.68	19.97
TSR-NN (1,6,1)	12.23	17.25	ARIMAX-NN (3,6,1)	11.69	20.64
TSR-NN (1,7,1)	11.86	16.15	ARIMAX-NN (3,7,1)	10.95	20.98
TSR-NN (1,8,1)	12.08	16.35	ARIMAX-NN (3,8,1)	10.46	23.33
TSR-NN (1,9,1)	11.46	16.00	ARIMAX-NN (3,9,1)	10.85	20.93
TSR-NN (1,10,1)	11.59	18.05	ARIMAX-NN (3,10,1)	9.87	21.76




- Penumpang Domestik yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	6.45	5.79	ARIMAX	7.28	5.74
TSR-NN (4,1,1)	5.58	5.46	ARIMAX-NN (2,1,1)	6.31	5.73
TSR-NN (4,2,1)	5.22	6.84	ARIMAX-NN (2,2,1)	6.24	6.56
TSR-NN (4,3,1)	5.05	6.19	ARIMAX-NN (2,3,1)	6.29	6.10
TSR-NN (4,4,1)	5.46	5.32	ARIMAX-NN (2,4,1)	5.99	6.20
TSR-NN (4,5,1)	4.68	5.74	ARIMAX-NN (2,5,1)	6.07	15.65
TSR-NN (4,6,1)	4.12	7.16	ARIMAX-NN (2,6,1)	6.02	6.03
TSR-NN (4,7,1)	4.27	7.74	ARIMAX-NN (2,7,1)	5.78	6.08
TSR-NN (4,8,1)	4.19	6.75	ARIMAX-NN (2,8,1)	5.99	5.60
TSR-NN (4,9,1)	4.34	5.75	ARIMAX-NN (2,9,1)	5.70	32.25
TSR-NN (4,10,1)	4.17	16.11	ARIMAX-NN (2,10,1)	5.53	35.81




Model	Akurasi Peramalan
-------	-------------------

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	6.48	9.22	ARIMAX	5.44	7.61
TSR-NN (3,1,1)	5.32	11.14	ARIMAX-NN (3,1,1)	4.88	7.81
TSR-NN (3,2,1)	5.05	8.09	ARIMAX-NN (3,2,1)	4.95	7.51
TSR-NN (3,3,1)	5.12	9.90	ARIMAX-NN (3,3,1)	4.79	16.53
TSR-NN (3,4,1)	5.13	9.11	ARIMAX-NN (3,4,1)	4.63	7.46
TSR-NN (3,5,1)	5.13	12.99	ARIMAX-NN (3,5,1)	4.34	7.03
TSR-NN (3,6,1)	5.13	9.80	ARIMAX-NN (3,6,1)	4.44	11.32
TSR-NN (3,7,1)	4.59	10.37	ARIMAX-NN (3,7,1)	4.21	8.39
TSR-NN (3,8,1)	4.24	9.19	ARIMAX-NN (3,8,1)	3.87	8.15
TSR-NN (3,9,1)	4.28	8.13	ARIMAX-NN (3,9,1)	3.94	10.69
TSR-NN (3,10,1)	4.08	6.26	ARIMAX-NN (3,10,1)	3.77	5.41




- Penumpang Internasional yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	5.84	12.43	ARIMAX	7.59	7.50
TSR-NN (3,1,1)	3.96	12.45	ARIMAX-NN (2,1,1)	6.42	7.31
TSR-NN (3,2,1)	3.87	11.00	ARIMAX-NN (2,2,1)	6.22	7.38
TSR-NN (3,3,1)	3.59	10.92	ARIMAX-NN (2,3,1)	5.74	9.21
TSR-NN (3,4,1)	3.67	18.41	ARIMAX-NN (2,4,1)	5.68	8.72
TSR-NN (3,5,1)	3.07	13.46	ARIMAX-NN (2,5,1)	5.83	8.12
TSR-NN (3,6,1)	3.04	15.66	ARIMAX-NN (2,6,1)	5.41	8.96
TSR-NN (3,7,1)	2.57	11.55	ARIMAX-NN (2,7,1)	5.00	8.98
TSR-NN (3,8,1)	2.47	20.58	ARIMAX-NN (2,8,1)	5.29	8.66
TSR-NN (3,9,1)	2.26	12.13	ARIMAX-NN (2,9,1)	5.25	10.54
TSR-NN (3,10,1)	2.02	28.04	ARIMAX-NN (2,10,1)	4.80	8.27





- Penumpang Internasional yang Datang

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	5.94	6.84	ARIMAX	6.59	6.96
TSR-NN (2,1,1)	5.40	6.94	ARIMAX-NN (3,1,1)	6.43	6.65
TSR-NN (2,2,1)	5.34	5.70	ARIMAX-NN (3,2,1)	6.23	7.09
TSR-NN (2,3,1)	4.94	6.78	ARIMAX-NN (3,3,1)	6.13	44.38
TSR-NN (2,4,1)	4.89	29.20	ARIMAX-NN (3,4,1)	5.92	6.77
TSR-NN (2,5,1)	4.98	6.95	ARIMAX-NN (3,5,1)	5.11	6.98
TSR-NN (2,6,1)	4.60	6.75	ARIMAX-NN (3,6,1)	5.28	8.51
TSR-NN (2,7,1)	4.64	6.97	ARIMAX-NN (3,7,1)	5.44	27.14
TSR-NN (2,8,1)	4.46	6.36	ARIMAX-NN (3,8,1)	5.16	22.22
TSR-NN (2,9,1)	4.18	50.29	ARIMAX-NN (3,9,1)	5.09	14.85
TSR-NN (2,10,1)	4.41	14.37	ARIMAX-NN (3,10,1)	4.61	18.16





- Kargo Domestik yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	10.37	49.43	ARIMAX	13.51	57.86
TSR-NN (3,1,1)	10.11	49.19	ARIMAX-NN (2,1,1)	13.45	58.49
TSR-NN (3,2,1)	10.07	50.63	ARIMAX-NN (2,2,1)	13.31	58.23
TSR-NN (3,3,1)	8.77	51.11	ARIMAX-NN (2,3,1)	12.75	59.37
TSR-NN (3,4,1)	9.61	50.02	ARIMAX-NN (2,4,1)	12.81	57.58
TSR-NN (3,5,1)	8.48	49.22	ARIMAX-NN (2,5,1)	12.78	57.68
TSR-NN (3,6,1)	7.27	55.28	ARIMAX-NN (2,6,1)	11.92	58.04
TSR-NN (3,7,1)	7.94	57.05	ARIMAX-NN (2,7,1)	11.68	57.07
TSR-NN (3,8,1)	6.84	59.20	ARIMAX-NN (2,8,1)	11.71	56.47
TSR-NN (3,9,1)	6.39	58.53	ARIMAX-NN (2,9,1)	11.09	57.14
TSR-NN (3,10,1)	5.44	55.01	ARIMAX-NN (2,10,1)	11.85	57.98





- Kargo Domestik yang Dibongkar

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPE _p		MAPE	MAPE _p
TSR	11.38	15.72	ARIMAX	12.06	24.55
TSR-NN (2,1,1)	10.96	14.44	ARIMAX-NN (2,1,1)	11.69	24.21
TSR-NN (2,2,1)	10.63	13.57	ARIMAX-NN (2,2,1)	11.16	25.62
TSR-NN (2,3,1)	9.84	15.61	ARIMAX-NN (2,3,1)	10.93	28.22
TSR-NN (2,4,1)	9.89	13.82	ARIMAX-NN (2,4,1)	10.99	42.93
TSR-NN (2,5,1)	8.85	16.71	ARIMAX-NN (2,5,1)	10.51	30.04
TSR-NN (2,6,1)	8.79	16.36	ARIMAX-NN (2,6,1)	10.71	30.47
TSR-NN (2,7,1)	9.33	106.94	ARIMAX-NN (2,7,1)	9.13	29.18
TSR-NN (2,8,1)	8.60	27.73	ARIMAX-NN (2,8,1)	10.08	29.23
TSR-NN (2,9,1)	7.87	40.13	ARIMAX-NN (2,9,1)	9.24	23.90
TSR-NN (2,10,1)	7.97	43.58	ARIMAX-NN (2,10,1)	9.02	26.38





- Kargo Internasional yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	9.18	38.73	ARIMAX	9.82	36.11
TSR-NN (2,1,1)	9.07	36.78	ARIMAX-NN (2,1,1)	8.67	36.11
TSR-NN (2,2,1)	8.92	37.81	ARIMAX-NN (2,2,1)	8.42	36.13
TSR-NN (2,3,1)	8.70	37.99	ARIMAX-NN (2,3,1)	8.35	36.51
TSR-NN (2,4,1)	9.06	35.06	ARIMAX-NN (2,4,1)	8.18	37.52
TSR-NN (2,5,1)	8.38	36.73	ARIMAX-NN (2,5,1)	8.17	35.00
TSR-NN (2,6,1)	8.14	46.49	ARIMAX-NN (2,6,1)	7.93	36.33
TSR-NN (2,7,1)	7.49	38.03	ARIMAX-NN (2,7,1)	7.61	37.00
TSR-NN (2,8,1)	7.91	36.98	ARIMAX-NN (2,8,1)	7.37	37.45
TSR-NN (2,9,1)	7.46	35.97	ARIMAX-NN (2,9,1)	7.45	35.37
TSR-NN (2,10,1)	7.31	50.99	ARIMAX-NN (2,10,1)	7.17	36.57



- Kargo Internasional yang Dibongkar



Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	15.48	26.35	ARIMAX	16.10	32.95
TSR-NN (2,1,1)	15.96	28.36	ARIMAX-NN (2,1,1)	15.59	37.57
TSR-NN (2,2,1)	16.20	26.85	ARIMAX-NN (2,2,1)	14.89	32.59
TSR-NN (2,3,1)	15.45	28.85	ARIMAX-NN (2,3,1)	15.46	37.88
TSR-NN (2,4,1)	15.69	26.18	ARIMAX-NN (2,4,1)	14.80	39.30
TSR-NN (2,5,1)	14.99	26.21	ARIMAX-NN (2,5,1)	14.69	211.09
TSR-NN (2,6,1)	15.62	27.06	ARIMAX-NN (2,6,1)	14.50	42.92
TSR-NN (2,7,1)	14.08	29.47	ARIMAX-NN (2,7,1)	13.74	57.42
TSR-NN (2,8,1)	15.11	28.01	ARIMAX-NN (2,8,1)	14.44	42.45
TSR-NN (2,9,1)	13.75	32.28	ARIMAX-NN (2,9,1)	13.35	58.63
TSR-NN (2,10,1)	14.20	41.76	ARIMAX-NN (2,10,1)	12.19	44.08



C. Bandara I Gusti Ngurah Rai



- Penumpang Domestik yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	6.00	15.05	ARIMAX	7.43	21.30
TSR-NN (4,1,1)	5.28	14.60	ARIMAX-NN (4,1,1)	6.25	21.45
TSR-NN (4,2,1)	4.79	14.25	ARIMAX-NN (4,2,1)	5.97	22.00
TSR-NN (4,3,1)	5.11	14.02	ARIMAX-NN (4,3,1)	5.73	20.87
TSR-NN (4,4,1)	4.70	14.05	ARIMAX-NN (4,4,1)	5.40	22.48
TSR-NN (4,5,1)	4.51	15.07	ARIMAX-NN (4,5,1)	5.31	21.98
TSR-NN (4,6,1)	4.55	14.36	ARIMAX-NN (4,6,1)	5.10	22.30
TSR-NN (4,7,1)	4.21	14.52	ARIMAX-NN (4,7,1)	4.63	21.25
TSR-NN (4,8,1)	3.68	15.21	ARIMAX-NN (4,8,1)	4.54	21.48
TSR-NN (4,9,1)	3.52	15.81	ARIMAX-NN (4,9,1)	4.41	21.36
TSR-NN (4,10,1)	2.99	14.87	ARIMAX-NN (4,10,1)	4.19	21.58





- Penumpang Domestik yang Datang

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	8.37	25.18	ARIMAX	5.86	6.55
TSR-NN (3,1,1)	5.64	25.58	ARIMAX-NN (2,1,1)	4.78	6.54
TSR-NN (3,2,1)	5.53	25.07	ARIMAX-NN (2,2,1)	4.76	6.51
TSR-NN (3,3,1)	5.50	25.77	ARIMAX-NN (2,3,1)	4.55	6.49
TSR-NN (3,4,1)	5.40	24.67	ARIMAX-NN (2,4,1)	4.51	6.46
TSR-NN (3,5,1)	5.18	25.87	ARIMAX-NN (2,5,1)	4.52	6.74
TSR-NN (3,6,1)	5.17	26.53	ARIMAX-NN (2,6,1)	4.28	6.73
TSR-NN (3,7,1)	4.41	24.68	ARIMAX-NN (2,7,1)	4.24	6.30
TSR-NN (3,8,1)	4.44	25.53	ARIMAX-NN (2,8,1)	4.28	6.43
TSR-NN (3,9,1)	4.50	23.07	ARIMAX-NN (2,9,1)	4.14	6.80
TSR-NN (3,10,1)	4.31	25.77	ARIMAX-NN (2,10,1)	3.82	7.06





- Penumpang Internasional yang Berangkat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	7.19	7.86	ARIMAX	9.34	6.89
TSR-NN (2,1,1)	6.52	7.58	ARIMAX-NN (2,1,1)	8.47	7.05
TSR-NN (2,2,1)	6.54	7.68	ARIMAX-NN (2,2,1)	8.23	6.53
TSR-NN (2,3,1)	6.17	8.78	ARIMAX-NN (2,3,1)	8.53	6.98
TSR-NN (2,4,1)	6.51	7.49	ARIMAX-NN (2,4,1)	7.80	6.61
TSR-NN (2,5,1)	6.05	9.15	ARIMAX-NN (2,5,1)	7.87	5.95
TSR-NN (2,6,1)	5.96	7.59	ARIMAX-NN (2,6,1)	7.56	7.05
TSR-NN (2,7,1)	5.59	7.89	ARIMAX-NN (2,7,1)	7.31	9.84
TSR-NN (2,8,1)	5.35	9.61	ARIMAX-NN (2,8,1)	6.85	5.88
TSR-NN (2,9,1)	5.47	7.77	ARIMAX-NN (2,9,1)	6.75	12.18
TSR-NN (2,10,1)	5.40	7.85	ARIMAX-NN (2,10,1)	6.70	18.15




- Penumpang Internasional yang Datang

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	7.38	12.19	ARIMAX	13.77	8.75
TSR-NN (2,1,1)	6.62	11.99	ARIMAX-NN (3,1,1)	9.94	9.07
TSR-NN (2,2,1)	6.60	11.58	ARIMAX-NN (3,2,1)	9.35	7.68
TSR-NN (2,3,1)	6.28	12.32	ARIMAX-NN (3,3,1)	9.36	7.13
TSR-NN (2,4,1)	6.10	12.92	ARIMAX-NN (3,4,1)	8.81	9.18
TSR-NN (2,5,1)	5.84	11.32	ARIMAX-NN (3,5,1)	9.09	7.89
TSR-NN (2,6,1)	6.07	12.32	ARIMAX-NN (3,6,1)	8.27	9.58
TSR-NN (2,7,1)	5.45	13.07	ARIMAX-NN (3,7,1)	8.09	8.14
TSR-NN (2,8,1)	5.09	13.27	ARIMAX-NN (3,8,1)	7.22	9.09
TSR-NN (2,9,1)	5.22	11.41	ARIMAX-NN (3,9,1)	6.70	9.84
TSR-NN (2,10,1)	5.15	13.25	ARIMAX-NN (3,10,1)	5.97	7.83





- Kargo Domestik yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	8.37	16.55	ARIMAX	9.77	23.76
TSR-NN (2,1,1)	7.93	16.06	ARIMAX-NN (1,1,1)	9.31	23.80
TSR-NN (2,2,1)	7.19	17.72	ARIMAX-NN (1,2,1)	9.35	23.82
TSR-NN (2,3,1)	7.19	17.25	ARIMAX-NN (1,3,1)	9.17	24.61
TSR-NN (2,4,1)	6.58	16.36	ARIMAX-NN (1,4,1)	9.18	22.10
TSR-NN (2,5,1)	6.04	18.07	ARIMAX-NN (1,5,1)	9.28	23.88
TSR-NN (2,6,1)	6.32	15.78	ARIMAX-NN (1,6,1)	9.12	21.99
TSR-NN (2,7,1)	6.49	22.32	ARIMAX-NN (1,7,1)	8.79	24.62
TSR-NN (2,8,1)	5.10	21.42	ARIMAX-NN (1,8,1)	8.63	24.52
TSR-NN (2,9,1)	4.59	16.54	ARIMAX-NN (1,9,1)	8.73	22.09
TSR-NN (2,10,1)	5.17	16.46	ARIMAX-NN (1,10,1)	8.21	22.01





- Kargo Domestik yang Dibongkar

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	12.08	7.16	ARIMAX	10.06	12.28
TSR-NN (4,1,1)	11.28	6.59	ARIMAX-NN (3,1,1)	9.06	13.00
TSR-NN (4,2,1)	10.43	12.72	ARIMAX-NN (3,2,1)	8.93	12.44
TSR-NN (4,3,1)	9.53	10.33	ARIMAX-NN (3,3,1)	8.61	14.05
TSR-NN (4,4,1)	9.86	9.38	ARIMAX-NN (3,4,1)	8.25	17.64
TSR-NN (4,5,1)	9.70	10.07	ARIMAX-NN (3,5,1)	7.77	13.77
TSR-NN (4,6,1)	8.25	10.11	ARIMAX-NN (3,6,1)	7.93	13.74
TSR-NN (4,7,1)	7.99	12.19	ARIMAX-NN (3,7,1)	7.88	16.13
TSR-NN (4,8,1)	6.30	13.89	ARIMAX-NN (3,8,1)	7.49	16.23
TSR-NN (4,9,1)	6.00	19.83	ARIMAX-NN (3,9,1)	6.89	17.04
TSR-NN (4,10,1)	5.09	14.44	ARIMAX-NN (3,10,1)	6.52	17.89





- Kargo Internasional yang Dimuat

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	13.68	14.04	ARIMAX	14.73	16.00
TSR-NN (2,1,1)	13.43	14.35	ARIMAX-NN (2,1,1)	14.60	15.55
TSR-NN (2,2,1)	13.57	14.23	ARIMAX-NN (2,2,1)	14.25	17.36
TSR-NN (2,3,1)	13.48	15.72	ARIMAX-NN (2,3,1)	13.83	14.88
TSR-NN (2,4,1)	13.37	15.44	ARIMAX-NN (2,4,1)	14.14	15.07
TSR-NN (2,5,1)	12.66	15.16	ARIMAX-NN (2,5,1)	13.20	14.53
TSR-NN (2,6,1)	12.16	15.29	ARIMAX-NN (2,6,1)	13.08	13.54
TSR-NN (2,7,1)	11.56	15.03	ARIMAX-NN (2,7,1)	12.98	15.46
TSR-NN (2,8,1)	11.96	13.98	ARIMAX-NN (2,8,1)	12.60	15.61
TSR-NN (2,9,1)	11.58	26.14	ARIMAX-NN (2,9,1)	12.67	18.73
TSR-NN (2,10,1)	11.38	12.41	ARIMAX-NN (2,10,1)	11.69	24.09



- Kargo Internasional yang Dibongkar

Model	Akurasi Peramalan		Model	Akurasi Peramalan	
	MAPE	MAPEp		MAPE	MAPEp
TSR	19.58	24.25	ARIMAX	20.58	19.57
TSR-NN (2,1,1)	18.41	24.79	ARIMAX-NN (1,1,1)	20.37	19.72
TSR-NN (2,2,1)	18.26	25.63	ARIMAX-NN (1,2,1)	20.03	19.97
TSR-NN (2,3,1)	17.72	25.36	ARIMAX-NN (1,3,1)	19.25	16.83
TSR-NN (2,4,1)	16.97	23.63	ARIMAX-NN (1,4,1)	19.22	16.87
TSR-NN (2,5,1)	17.75	23.89	ARIMAX-NN (1,5,1)	19.13	19.53
TSR-NN (2,6,1)	16.65	24.19	ARIMAX-NN (1,6,1)	18.41	17.95
TSR-NN (2,7,1)	16.55	25.03	ARIMAX-NN (1,7,1)	18.92	18.18
TSR-NN (2,8,1)	14.81	26.45	ARIMAX-NN (1,8,1)	17.75	17.42
TSR-NN (2,9,1)	15.78	27.16	ARIMAX-NN (1,9,1)	17.67	17.98
TSR-NN (2,10,1)	14.62	27.71	ARIMAX-NN (1,10,1)	17.46	17.38



Lampiran 11. Pemilihan Parameter Model *Hybrid* TSR-SVR dan ARIMAX-SVR dengan Menggunakan Metode *Grid Search*

A. Bandara Soekarno Hatta

- Penumpang Domestik yang Berangkat

Metode <i>Grid Search</i> Model TSR-SVR					Metode <i>Grid Search</i> Model ARIMAX-SVR				
<i>Epsilon</i>	C	σ^2	Akurasi Peramalan		<i>Epsilon</i>	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
750	1000	0.05	3.8945	5.2600	1000	1000	0.05	5.1069	5.1855
800	1000	0.05	3.8946	5.2600	1000	1000	0.06	5.1069	5.1855
850	1000	0.05	3.8947	5.2600	1000	1000	0.07	5.1069	5.1855
1000	3000	0.05	3.7218	5.2645	900	1000	0.05	5.1066	5.1859
1000	3000	0.06	3.7218	5.2645	900	1000	0.06	5.1066	5.1859
1000	3000	0.07	3.7218	5.2645	900	1000	0.07	5.1066	5.1859
450	3000	0.05	3.7183	5.2660	700	1000	0.05	5.1061	5.1860
450	3000	0.06	3.7183	5.2660	700	1000	0.06	5.1061	5.1860
450	3000	0.07	3.7183	5.2660	700	1000	0.07	5.1061	5.1860
1000	5000	0.05	3.5541	5.2698	100	3000	0.05	4.8984	5.1950
1000	5000	0.06	3.5541	5.2698	100	3000	0.06	4.8984	5.1950
1000	5000	0.07	3.5541	5.2698	100	3000	0.07	4.8984	5.1950
500	5000	0.05	3.5500	5.2710	100	5000	0.05	4.6994	5.2043
500	5000	0.06	3.5500	5.2710	100	5000	0.06	4.6994	5.2043
500	5000	0.07	3.5500	5.2710	100	5000	0.07	4.6994	5.2043

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 750 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 172

Objective Function Value : -8431823609
Training error : 4305093293.33138
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 1000 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 185

Objective Function Value : -10237803169
Training error : 5439390861.44429
```

- Penumpang Domestik yang Datang

Metode <i>Grid Search</i> Model TSR-SVR					Metode <i>Grid Search</i> Model ARIMAX-SVR				
<i>Epsilon</i>	C	σ^2	Akurasi Peramalan		<i>Epsilon</i>	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.1	5.1826	6.4150	100	1000	0.1	6.1659	5.4696
100	1000	0.09	5.1826	6.4150	150	1000	0.1	6.1659	5.4696
450	5000	0.1	5.1737	6.5137	200	1000	0.1	6.1659	5.4696
450	5000	0.09	5.1737	6.5137	100	3000	0.1	5.9920	5.4775
800	9000	0.08	5.1817	6.6032	100	3000	0.08	5.9920	5.4775
800	9000	0.07	5.1817	6.6032	100	3000	0.09	5.9920	5.4775
550	19000	0.1	5.2138	6.7863	100	5000	0.05	5.8227	5.4858
550	19000	0.09	5.2138	6.7863	100	5000	0.06	5.8227	5.4858
550	19000	0.08	5.2138	6.7863	100	5000	0.07	5.8227	5.4858
750	23000	0.05	5.2381	6.8546	100	9000	0.06	5.4982	5.5022
650	23000	0.1	5.2381	6.8546	100	9000	0.05	5.4982	5.5022
650	23000	0.09	5.2381	6.8546	100	9000	0.07	5.4982	5.5022
100	37000	0.1	5.3606	7.0381	100	11000	0.06	5.3412	5.5105
100	37000	0.09	5.3606	7.0381	100	11000	0.05	5.3412	5.5105
100	37000	0.08	5.3606	7.0381	100	11000	0.07	5.3412	5.5105

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 175

Objective Function Value : -12761089330
Training error : 9041126976.59866
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1

Number of Support Vectors : 188

Objective Function Value : -14540317996
Training error : 10126472566.3245
```


- Penumpang Internasional yang Berangkat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	25000	0.07	1.6375	5.1948	1000	11000	0.05	2.5971	4.4332
100	25000	0.05	1.6375	5.1948	1000	11000	0.06	2.5971	4.4332
100	25000	0.06	1.6375	5.1948	1000	11000	0.07	2.5971	4.4332
700	25000	0.07	1.7674	5.1957	100	13000	0.07	2.1701	4.4402
700	25000	0.05	1.7674	5.1957	100	13000	0.08	2.1701	4.4402
700	25000	0.06	1.7674	5.1957	100	13000	0.09	2.1701	4.4402
950	23000	0.1	2.0030	5.1981	1000	9000	0.05	2.9291	4.4609
950	23000	0.09	2.0030	5.1981	1000	9000	0.06	2.9291	4.4609
950	23000	0.08	2.0030	5.1981	1000	9000	0.07	2.9291	4.4609
300	23000	0.1	1.8671	5.1993	100	15000	0.07	1.8925	4.4681
300	23000	0.09	1.8671	5.1993	100	15000	0.08	1.8925	4.4681
300	23000	0.08	1.8671	5.1993	100	15000	0.09	1.8925	4.4681
250	27000	0.07	1.4967	5.2221	950	7000	0.05	3.3006	4.4888
250	27000	0.05	1.4967	5.2221	950	7000	0.06	3.3006	4.4888
250	27000	0.06	1.4967	5.2221	950	7000	0.07	3.3006	4.4888

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 25000	parameter : epsilon = 1000 cost C = 11000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.07	Hyperparameter : sigma = 0.05
Number of Support Vectors : 176	Number of Support Vectors : 165
Objective Function Value : -50842555693	Objective Function Value : -23494599602
Training error : 166947195.458283	Training error : 268981999.316993

- Penumpang Internasional yang Datang

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.1	6.1881	6.8610	100	43000	0.1	0.4311	6.6997
100	1000	0.05	6.1881	6.8610	100	43000	0.09	0.4311	6.6997
100	1000	0.06	6.1881	6.8610	100	43000	0.08	0.4311	6.6997
150	1000	0.05	6.1894	6.8614	1000	41000	0.05	0.7555	6.7274
150	1000	0.1	6.1894	6.8614	1000	41000	0.06	0.7555	6.7274
150	1000	0.06	6.1894	6.8614	1000	41000	0.07	0.7555	6.7274
950	1000	0.1	6.2113	6.8663	200	45000	0.1	0.4090	6.7293
950	1000	0.08	6.2113	6.8663	200	45000	0.09	0.4090	6.7293
950	1000	0.09	6.2113	6.8663	200	45000	0.08	0.4090	6.7293
1000	3000	0.09	5.6814	6.8915	1000	39000	0.05	0.8209	6.7576
1000	3000	0.1	5.6814	6.8915	1000	39000	0.06	0.8209	6.7576
1000	3000	0.08	5.6814	6.8915	1000	39000	0.07	0.8209	6.7576
200	5000	0.1	5.1532	6.9200	1000	37000	0.05	0.8916	6.7876
200	5000	0.09	5.1532	6.9200	1000	37000	0.06	0.8916	6.7876
200	5000	0.08	5.1532	6.9200	1000	37000	0.07	0.8916	6.7876

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000	parameter : epsilon = 100 cost C = 43000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1	Hyperparameter : sigma = 0.1
Number of Support Vectors : 175	Number of Support Vectors : 186
Objective Function Value : -3885102797	Objective Function Value : -72139212075
Training error : 904399816.908191	Training error : 102584061.389202

- Kargo Domestik yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.1	2.0632	12.8588	1000	1000	0.05	5.2612	11.8060
99	1000	0.1	2.0574	12.8589	1000	1000	0.06	5.2612	11.8060
98	1000	0.1	2.0516	12.8589	1000	1000	0.07	5.2612	11.8060
97	1000	0.1	2.0457	12.8590	500	1000	0.05	3.9031	11.8102
100	1000	0.09	2.0645	12.8590	500	1000	0.06	3.9031	11.8102
96	1000	0.1	2.0398	12.8590	500	1000	0.07	3.9031	11.8102
99	1000	0.09	2.0587	12.8590	1000	5000	0.07	5.1002	12.0152
95	1000	0.1	2.0340	12.8591	1000	5000	0.08	5.1002	12.0152
98	1000	0.09	2.0528	12.8591	1000	5000	0.09	5.1002	12.0152
94	1000	0.1	2.0281	12.8591	950	3000	0.07	4.9839	12.0370
97	1000	0.09	2.0469	12.8591	950	3000	0.08	4.9839	12.0370
93	1000	0.1	2.0223	12.8591	950	3000	0.09	4.9839	12.0370
100	1000	0.08	2.0660	12.8592	900	3000	0.05	4.8561	12.0589
96	1000	0.09	2.0411	12.8592	900	3000	0.06	4.8561	12.0589
92	1000	0.1	2.0165	12.8592	900	3000	0.07	4.8561	12.0589

<pre>> model.optimal Support Vector Machine object of class "ksvm" SV type: eps-svr (regression) parameter : epsilon = 100 cost C = 1000 Gaussian Radial Basis kernel function. Hyperparameter : sigma = 0.1 Number of Support Vectors : 171 Objective Function Value : -83232309 Training error : 354061.355095</pre>	<pre>> model.optimal Support Vector Machine object of class "ksvm" SV type: eps-svr (regression) parameter : epsilon = 1000 cost C = 1000 Gaussian Radial Basis kernel function. Hyperparameter : sigma = 0.05 Number of Support Vectors : 53 Objective Function Value : -21298174 Training error : 640280.367349</pre>
---	--

- Kargo Domestik yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
10	1000	0.05	0.6718	14.4103	100	1000	0.05	1.9988	13.9569
10	1000	0.06	0.6718	14.4103	100	1000	0.06	1.9988	13.9569
10	1000	0.07	0.6718	14.4103	100	1000	0.07	1.9988	13.9569
13	1000	0.05	0.7194	14.4106	200	1000	0.05	3.3466	13.9764
13	1000	0.06	0.7194	14.4106	200	1000	0.06	3.3466	13.9764
13	1000	0.07	0.7194	14.4106	200	1000	0.07	3.3466	13.9764
18	1000	0.05	0.7979	14.4111	300	1000	0.05	4.4140	13.9959
18	1000	0.06	0.7979	14.4111	300	1000	0.06	4.4140	13.9959
18	1000	0.07	0.7979	14.4111	300	1000	0.07	4.4140	13.9959
99	1000	0.05	1.9761	14.4203	600	1000	0.05	6.2180	14.1153
99	1000	0.06	1.9761	14.4203	600	1000	0.06	6.2180	14.1153
99	1000	0.07	1.9761	14.4203	600	1000	0.07	6.2180	14.1153
100	3000	0.05	1.6451	16.3893	750	1000	0.05	6.7425	14.1541
100	5000	0.05	1.6451	16.3893	750	1000	0.06	6.7425	14.1541
100	7000	0.05	1.6451	16.3893	750	1000	0.07	6.7425	14.1541

<pre>> model.optimal Support Vector Machine object of class "ksvm" SV type: eps-svr (regression) parameter : epsilon = 10 cost C = 1000 Gaussian Radial Basis kernel function. Hyperparameter : sigma = 0.05 Number of Support Vectors : 175 Objective Function Value : -36817005 Training error : 58051.732971</pre>	<pre>> model.optimal Support Vector Machine object of class "ksvm" SV type: eps-svr (regression) parameter : epsilon = 100 cost C = 1000 Gaussian Radial Basis kernel function. Hyperparameter : sigma = 0.05 Number of Support Vectors : 165 Objective Function Value : -26561265 Training error : 63494.396761</pre>
--	---

- Kargo Internasional yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
1000	1000	0.05	8.1239	17.6745	1000	5000	0.1	7.5895	15.7401
1000	1000	0.06	8.1239	17.6745	1000	7000	0.1	7.5895	15.7401
1000	1000	0.07	8.1239	17.6745	1000	9000	0.1	7.5895	15.7401
950	1000	0.06	7.9561	17.6760	550	1000	0.05	6.9376	15.7528
950	1000	0.07	7.9561	17.6760	550	1000	0.06	6.9376	15.7528
950	1000	0.08	7.9561	17.6760	550	1000	0.07	6.9376	15.7528
850	1000	0.05	7.6013	17.6803	400	1000	0.05	6.0811	15.7626
850	1000	0.06	7.6013	17.6803	400	1000	0.06	6.0811	15.7626
850	1000	0.07	7.6013	17.6803	400	1000	0.07	6.0811	15.7626
600	1000	0.05	6.5736	17.7020	950	11000	0.07	7.3592	15.7670
600	1000	0.06	6.5736	17.7020	950	11000	0.08	7.3592	15.7670
600	1000	0.07	6.5736	17.7020	950	11000	0.09	7.3592	15.7670
500	1000	0.05	6.1200	17.7173	100	1000	0.05	4.1707	15.7859
500	1000	0.06	6.1200	17.7173	100	1000	0.06	4.1707	15.7859
500	1000	0.07	6.1200	17.7173	100	1000	0.07	4.1707	15.7859

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 1000 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 72

Objective Function Value : -35435918
Training error : 896646.912771
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 1000 cost C = 5000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1

Number of Support Vectors : 89

Objective Function Value : -57773173
Training error : 603985.238846
```

- Kargo Internasional yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
96	1000	0.06	5.3075	18.4438	1000	1000	0.05	10.8160	20.0217
97	1000	0.06	5.3136	18.4438	1000	1000	0.06	10.8160	20.0217
98	1000	0.06	5.3197	18.4438	1000	1000	0.07	10.8160	20.0217
100	1000	0.09	5.2209	18.4448	500	1000	0.05	8.4132	20.0302
70	1000	0.09	5.0309	18.4448	500	1000	0.06	8.4132	20.0302
69	1000	0.09	5.0244	18.4449	500	1000	0.07	8.4132	20.0302
25	1000	0.09	4.7381	18.4460	200	1000	0.05	6.6858	20.0434
22	1000	0.07	4.7933	18.4460	200	1000	0.06	6.6858	20.0434
57	1000	0.05	5.1331	18.4460	200	1000	0.07	6.6858	20.0434
46	1000	0.05	5.0653	18.4467	1000	3000	0.05	9.3271	21.0532
13	1000	0.1	4.6282	18.4467	1000	3000	0.06	9.3271	21.0532
24	1000	0.06	4.8574	18.4467	1000	3000	0.07	9.3271	21.0532
100	3000	0.1	2.3442	19.5081	700	3000	0.05	7.3845	21.0610
99	3000	0.1	2.3345	19.5082	700	3000	0.06	7.3845	21.0610
98	3000	0.1	2.3249	19.5082	700	3000	0.07	7.3845	21.0610

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 96 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.06

Number of Support Vectors : 180

Objective Function Value : -136672727.3
Training error : 948621.585851
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 1000 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 104

Objective Function Value : -74746899
Training error : 1673831.828814
```


B. Bandara I Gusti Ngurah Rai

- Penumpang Domestik yang Berangkat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.05	5.2962	6.94501	100	37000	0.05	0.15667	9.21873
100	1000	0.06	5.2962	6.94501	100	37000	0.06	0.15667	9.21873
100	1000	0.07	5.2962	6.94501	100	37000	0.08	0.15667	9.21873
100	5000	0.05	5.5151	7.01446	150	37000	0.05	0.18497	9.21877
100	5000	0.06	5.5151	7.01446	150	37000	0.06	0.18497	9.21877
100	5000	0.07	5.5151	7.01446	150	37000	0.08	0.18497	9.21877
100	7000	0.05	5.7315	7.04597	1000	37000	0.05	0.65256	9.21958
100	7000	0.06	5.7315	7.04597	1000	37000	0.06	0.65256	9.21958
100	7000	0.07	5.7315	7.04597	1000	37000	0.08	0.65256	9.21958
100	9000	0.05	5.9194	7.05181	700	35000	0.08	0.54058	9.22155
100	9000	0.06	5.9194	7.05181	700	35000	0.05	0.54058	9.22155
100	9000	0.07	5.9194	7.05181	700	35000	0.06	0.54058	9.22155
800	7000	0.05	5.7144	7.04029	200	39000	0.09	0.17391	9.25203
800	7000	0.05	5.7144	7.04029	200	39000	0.1	0.17391	9.25203
800	7000	0.05	5.7144	7.04029	200	39000	0.05	0.17391	9.25203

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000	parameter : epsilon = 100 cost C = 37000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05	Hyperparameter : sigma = 0.05
Number of Support Vectors : 160	Number of Support Vectors : 188
Objective Function Value : -1936714124	Objective Function Value : -30142249050
Training error : 255831867.563677	Training error : 5580489.130047

- Penumpang Domestik yang Datang

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
250	5000	0.05	3.5427	7.1877	650	5000	0.05	3.1946	9.3534
250	5000	0.06	3.5427	7.1877	650	5000	0.06	3.1946	9.3534
250	5000	0.07	3.5427	7.1877	650	5000	0.07	3.1946	9.3534
450	5000	0.06	3.5725	7.1878	750	3000	0.1	3.9409	9.3627
450	5000	0.07	3.5725	7.1878	750	3000	0.09	3.9409	9.3627
450	5000	0.08	3.5725	7.1878	750	3000	0.08	3.9409	9.3627
650	3000	0.05	4.3164	7.2111	200	7000	0.05	2.4862	9.3897
650	3000	0.06	4.3164	7.2111	200	7000	0.06	2.4862	9.3897
650	3000	0.07	4.3164	7.2111	200	7000	0.07	2.4862	9.3897
850	1000	0.05	5.1455	7.2466	1000	7000	0.05	2.7113	9.3903
850	1000	0.06	5.1455	7.2466	1000	7000	0.06	2.7113	9.3903
850	1000	0.07	5.1455	7.2466	1000	7000	0.07	2.7113	9.3903
900	9000	0.05	2.5486	7.2594	1000	1000	0.1	4.8717	9.4003
900	9000	0.06	2.5486	7.2594	1000	1000	0.09	4.8717	9.4003
900	9000	0.07	2.5486	7.2594	1000	1000	0.08	4.8717	9.4003

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 250 cost C = 5000	parameter : epsilon = 650 cost C = 5000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05	Hyperparameter : sigma = 0.05
Number of Support Vectors : 173	Number of Support Vectors : 185
Objective Function Value : -9993399207	Objective Function Value : -8367100198
Training error : 266650260.25409	Training error : 170049331.863237

- Penumpang Internasional yang Berangkat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	15000	0.1	5.7753	12.6169	100	83000	0.08	0.1274	7.4839
100	15000	0.09	5.7753	12.6169	100	83000	0.06	0.1274	7.4839
100	15000	0.08	5.7753	12.6169	100	83000	0.05	0.1274	7.4839
150	9000	0.1	5.2136	12.6176	150	35000	0.05	0.4935	7.4845
200	27000	0.07	6.1664	12.6183	150	35000	0.06	0.4935	7.4845
200	29000	0.07	6.2024	12.6183	150	35000	0.09	0.4935	7.4845
250	23000	0.05	6.0827	12.6189	250	91000	0.05	0.1630	7.4859
250	27000	0.1	6.1590	12.6189	250	49000	0.05	0.4018	7.4859
250	29000	0.1	6.1950	12.6189	250	49000	0.06	0.4018	7.4859
300	11000	0.1	5.4304	12.6196	300	59000	0.05	0.3626	7.4866
300	11000	0.09	5.4304	12.6196	300	77000	0.05	0.2663	7.4866
300	11000	0.08	5.4304	12.6196	300	39000	0.05	0.5164	7.4866
400	15000	0.09	5.7439	12.6209	350	47000	0.08	0.4707	7.4872
400	15000	0.1	5.7439	12.6209	350	47000	0.09	0.4707	7.4872
400	33000	0.1	6.2235	12.6209	350	83000	0.06	0.2595	7.4872

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 15000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1

Number of Support Vectors : 104

Objective Function Value : -8365412307
Training error : 22581340.675476
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 83000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.08

Number of Support Vectors : 154

Objective Function Value : -33393992456
Training error : 11006152.157758
```

- Penumpang Internasional yang Datang

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
200	1000	0.05	4.8804	7.7260	100	55000	0.1	0.1005	8.5951
200	1000	0.06	4.8804	7.7260	100	83000	0.1	0.0581	8.5951
200	1000	0.07	4.8804	7.7260	100	17000	0.1	1.0480	8.5951
500	1000	0.05	4.8942	7.7262	200	79000	0.09	0.1162	8.5966
500	1000	0.06	4.8942	7.7262	200	19000	0.09	0.8772	8.5966
500	1000	0.07	4.8942	7.7262	200	45000	0.1	0.1926	8.5966
600	1000	0.05	4.8983	7.7265	250	21000	0.1	0.7422	8.5974
600	1000	0.06	4.8983	7.7265	250	17000	0.1	1.1170	8.5974
600	1000	0.07	4.8983	7.7265	250	33000	0.1	0.3830	8.5974
650	1000	0.05	4.9002	7.7267	300	11000	0.1	2.2623	8.5982
650	1000	0.06	4.9002	7.7267	300	71000	0.1	0.1771	8.5982
650	1000	0.07	4.9002	7.7267	300	23000	0.1	0.6570	8.5982
750	1000	0.1	4.9042	7.7270	350	29000	0.09	0.5146	8.5989
800	1000	0.05	4.9061	7.7271	350	61000	0.08	0.2261	8.5989
800	1000	0.06	4.9061	7.7271	350	81000	0.07	0.2010	8.5989

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 200 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 173

Objective Function Value : -1828563719
Training error : 233718639.718577
```

```
> model.optimal
Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 55000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1

Number of Support Vectors : 188

Objective Function Value : -28889870283
Training error : 10271965.710566
```


- Kargo Domestik yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.07	21.8245	50.7902	100	100	0.07	14.7770	42.6942
100	3000	0.07	21.8509	50.7902	100	100	0.06	14.7604	42.6992
100	5000	0.07	21.8509	50.7902	100	100	0.08	14.7695	42.7006
98	97000	0.08	21.4098	50.7964	100	100	0.1	14.7802	42.7129
98	99000	0.08	21.4098	50.7964	90	100	0.06	13.7687	42.9943
98	3000	0.07	21.4107	50.7964	90	100	0.05	13.7606	42.9947
75	99000	0.1	16.4202	50.8677	90	100	0.07	13.7581	43.0023
75	1000	0.1	16.3958	50.8677	90	100	0.08	13.7452	43.0113
75	3000	0.08	16.4221	50.8677	90	100	0.09	13.7344	43.0176
74	99000	0.1	16.2041	50.8708	90	100	0.1	13.7249	43.0222
73	3000	0.09	15.9889	50.8739	80	100	0.05	12.7747	43.3130
73	5000	0.09	15.9889	50.8739	80	100	0.06	12.7648	43.3222
41	1000	0.08	9.0574	50.9731	80	100	0.07	12.7515	43.3351
41	3000	0.08	9.0748	50.9731	80	100	0.08	12.7414	43.3432
41	5000	0.08	9.0748	50.9731	80	100	0.09	12.7292	43.3507

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.07

Number of Support Vectors : 121

Objective Function Value : -2768126

Training error : 9185.919647

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 100

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.07

Number of Support Vectors : 76

Objective Function Value : -1163475

Training error : 52807.064487

- Kargo Domestik yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
10	1000	0.05	0.67177	14.4103	100	100	0.1	9.3765	13.8407
10	1000	0.06	0.67177	14.4103	100	100	0.09	9.3761	13.8407
10	1000	0.07	0.67177	14.4103	100	100	0.08	9.3755	13.8408
13	1000	0.05	0.71941	14.4106	100	100	0.07	9.3746	13.8409
13	1000	0.06	0.71941	14.4106	100	100	0.06	9.3736	13.8412
13	1000	0.07	0.71941	14.4106	100	100	0.05	9.3723	13.8416
18	1000	0.05	0.79789	14.4111	90	100	0.1	9.0114	13.8429
18	1000	0.06	0.79789	14.4111	90	100	0.09	9.0114	13.8430
18	1000	0.07	0.79789	14.4111	90	100	0.08	9.0114	13.8430
99	1000	0.05	1.97612	14.4203	90	100	0.07	9.0113	13.8431
99	1000	0.06	1.97612	14.4203	90	100	0.06	9.0114	13.8433
99	1000	0.07	1.97612	14.4203	90	100	0.05	9.0118	13.8436
100	3000	0.05	1.64511	16.3893	80	100	0.05	8.6075	13.8456
100	5000	0.05	1.64511	16.3893	80	100	0.1	8.6053	13.8459
100	7000	0.05	1.64511	16.3893	80	100	0.06	8.6052	13.8459

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.1

Number of Support Vectors : 78

Objective Function Value : -544061.5

Training error : 5737.465709

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 100

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.1

Number of Support Vectors : 86

Objective Function Value : -552345.7

Training error : 14047.755915

- Kargo Internasional yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
10	100	0.1	5.5141	35.7975	10	100	0.05	5.1683	46.8471
10	100	0.09	5.5148	35.8034	10	100	0.06	5.1703	46.8471
10	100	0.08	5.5158	35.8104	10	100	0.07	5.1714	46.8471
10	100	0.07	5.5176	35.8190	10	50	0.06	6.8930	46.8475
10	100	0.06	5.5204	35.8293	10	50	0.07	6.8937	46.8475
10	100	0.05	5.5246	35.8421	10	50	0.08	6.8940	46.8475
20	100	0.09	5.6655	35.8999	250	130	0.1	7.8717	46.8476
20	100	0.1	5.6648	35.9010	250	140	0.05	7.8209	46.8476
20	100	0.08	5.6663	35.9069	250	140	0.06	7.8218	46.8476
20	100	0.07	5.6676	35.9159	250	140	0.07	7.8223	46.8476
20	100	0.06	5.6697	35.9268	250	140	0.08	7.8226	46.8476
20	100	0.05	5.6727	35.9401	250	140	0.09	7.8228	46.8476
10	90	0.1	5.8241	35.9681	10	510	0.07	0.7170	46.8480
10	90	0.09	5.8247	35.9733	260	500	0.05	7.6206	46.8480
10	90	0.08	5.8258	35.9796	260	500	0.06	7.6205	46.8480

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 10 cost C = 100	parameter : epsilon = 100 cost C = 1e+05
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1	Hyperparameter : sigma = 0.1
Number of Support Vectors : 188	Number of Support Vectors : 138
Objective Function Value : -4182903	Objective Function Value : -12359800
Training error : 150295.740203	Training error : 8112.989039

- Kargo Internasional yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	3000	0.09	11.223385	31.5594	100	3000	0.06	12.7264	22.9036
100	5000	0.09	11.2234	31.5594	100	5000	0.06	12.7264	22.9036
100	7000	0.09	11.2234	31.5594	100	7000	0.06	12.7264	22.9036
99	99000	0.09	11.1531	31.5654	95	97000	0.08	12.2494	22.9339
99	1000	0.08	11.0753	31.5654	95	99000	0.08	12.2494	22.9339
99	1000	0.06	11.0807	31.5654	95	1000	0.08	12.1349	22.9339
97	99000	0.09	11.0109	31.5776	80	95000	0.09	10.7555	20.0434
97	1000	0.07	10.9415	31.5776	80	97000	0.09	6.6858	20.0434
97	1000	0.1	10.9376	31.5776	80	99000	0.09	6.6858	20.0434
95	97000	0.06	10.8683	31.5897	1000	3000	0.05	9.3271	21.0532
95	99000	0.06	10.8683	31.5897	1000	3000	0.06	9.3271	21.0532
95	1000	0.09	10.7997	31.5897	1000	3000	0.07	9.3271	21.0532
95	1000	0.07	10.8025	31.5897	700	3000	0.05	7.3845	21.0610
94	1000	0.07	10.7323	31.5957	700	3000	0.06	7.3845	21.0610
94	3000	0.09	10.7845	31.5957	700	3000	0.07	7.3845	21.0610

<code>> model.optimal</code>	<code>> model.optimal</code>
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 3000	parameter : epsilon = 100 cost C = 3000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.09	Hyperparameter : sigma = 0.06
Number of Support Vectors : 89	Number of Support Vectors : 101
Objective Function Value : -1522795	Objective Function Value : -2808916
Training error : 6132.737453	Training error : 6760.693654

C. Bandara Juanda

- Penumpang Domestik yang Berangkat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	97000	0.1	0.0488	9.4905	100	37000	0.05	0.9601	7.1608
100	93000	0.1	0.0536	9.4905	100	37000	0.07	0.9601	7.1608
100	81000	0.1	0.0712	9.4905	100	37000	0.06	0.9601	7.1608
150	97000	0.1	0.0625	9.4910	450	37000	0.09	1.0386	7.1609
150	99000	0.1	0.0602	9.4910	450	37000	0.1	1.0386	7.1609
150	93000	0.1	0.0673	9.4910	450	37000	0.08	1.0386	7.1609
250	43000	0.05	0.3924	9.4921	500	37000	0.05	1.0497	7.1609
250	49000	0.05	0.2800	9.4921	500	37000	0.07	1.0497	7.1609
250	41000	0.05	0.4374	9.4921	500	37000	0.06	1.0497	7.1609
300	89000	0.1	0.1128	9.4926	850	35000	0.09	1.2310	7.1690
300	97000	0.1	0.1033	9.4926	850	35000	0.05	1.2310	7.1690
300	87000	0.1	0.1152	9.4926	850	35000	0.1	1.2310	7.1690
350	95000	0.1	0.1191	9.4931	250	39000	0.05	0.8947	7.1827
350	81000	0.1	0.1393	9.4931	250	39000	0.07	0.8947	7.1827
350	77000	0.1	0.1468	9.4931	250	39000	0.09	0.8947	7.1827

> model.optimal	> model.optimal
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 97000	parameter : epsilon = 100 cost C = 37000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1	Hyperparameter : sigma = 0.05
Number of Support Vectors : 175	Number of Support Vectors : 175
Objective Function Value : -119280374297	Objective Function Value : -122861899632
Training error : 123367668.785621	Training error : 793186935.121515

- Penumpang Domestik yang Datang

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	99000	0.05	0.0501	10.5697	1000	29000	0.07	1.0870	5.5057
100	97000	0.05	0.0531	10.5697	1000	29000	0.08	1.0870	5.5057
100	95000	0.05	0.0562	10.5697	1000	29000	0.09	1.0870	5.5057
150	97000	0.05	0.0655	10.5703	750	29000	0.05	1.0430	5.5060
150	95000	0.05	0.0685	10.5703	750	29000	0.06	1.0430	5.5060
150	99000	0.05	0.0626	10.5703	750	29000	0.1	1.0430	5.5060
250	97000	0.1	0.0904	10.5714	650	29000	0.05	1.0253	5.5061
250	99000	0.1	0.0875	10.5714	650	29000	0.06	1.0253	5.5061
250	95000	0.1	0.0933	10.5714	650	29000	0.1	1.0253	5.5061
300	95000	0.05	0.1057	10.5720	100	29000	0.05	0.9280	5.5066
300	99000	0.05	0.0999	10.5720	100	29000	0.06	0.9280	5.5066
300	97000	0.05	0.1028	10.5720	100	29000	0.1	0.9280	5.5066
400	97000	0.05	0.1276	10.5732	100	27000	0.1	1.0659	5.5105
400	99000	0.05	0.1247	10.5732	100	27000	0.09	1.0659	5.5105
400	95000	0.05	0.1305	10.5732	100	27000	0.08	1.0659	5.5105

> model.optimal	> model.optimal
Support Vector Machine object of class "ksvm"	Support Vector Machine object of class "ksvm"
SV type: eps-svr (regression)	SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 99000	parameter : epsilon = 1000 cost C = 29000
Gaussian Radial Basis kernel function.	Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05	Hyperparameter : sigma = 0.07
Number of Support Vectors : 190	Number of Support Vectors : 185
Objective Function Value : -2.35236e+11	Objective Function Value : -68010574090
Training error : 451894050.686477	Training error : 197852091.886468

- Penumpang Internasional yang Berangkat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
1000	7000	0.05	2.2845	9.2862	250	1000	0.05	6.5005	9.1650
1000	7000	0.06	2.2845	9.2862	250	1000	0.06	6.5005	9.1650
1000	7000	0.07	2.2845	9.2862	250	1000	0.07	6.5005	9.1650
1000	95000	0.05	2.1567	9.2862	200	1000	0.08	6.4727	9.1654
1000	97000	0.05	2.1567	9.2862	200	1000	0.09	6.4727	9.1654
1000	99000	0.05	2.1567	9.2862	200	1000	0.1	6.4727	9.1654
950	7000	0.05	2.1934	9.2917	150	1000	0.05	6.4438	9.1656
950	7000	0.06	2.1934	9.2917	150	1000	0.06	6.4438	9.1656
950	7000	0.07	2.1934	9.2917	150	1000	0.07	6.4438	9.1656
900	5000	0.08	2.4673	9.2972	400	1000	0.08	6.5742	9.1667
900	5000	0.09	2.4673	9.2972	400	1000	0.09	6.5742	9.1667
900	5000	0.1	2.4673	9.2972	400	1000	0.1	6.5742	9.1667
850	11000	0.1	1.8662	9.3027	450	1000	0.05	6.5964	9.1671
850	11000	0.09	1.8662	9.3027	450	1000	0.06	6.5964	9.1671
850	11000	0.08	1.8662	9.3027	450	1000	0.07	6.5964	9.1671

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 1000 cost C = 7000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.05

Number of Support Vectors : 131

Objective Function Value : -940055148

Training error : 1600390.601755

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 250 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.05

Number of Support Vectors : 180

Objective Function Value : -587863839

Training error : 19607480.614873

- Penumpang Internasional yang Datang

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	3000	0.1	2.7968	8.7974	1000	1000	0.05	8.7061	10.2309
100	3000	0.09	2.7968	8.7974	1000	1000	0.06	8.7061	10.2309
100	3000	0.08	2.7968	8.7974	1000	1000	0.07	8.7061	10.2309
150	13000	0.08	0.2885	8.8029	950	1000	0.08	8.6865	10.2325
150	13000	0.09	0.2885	8.8029	950	1000	0.09	8.6865	10.2325
150	13000	0.1	0.2885	8.8029	950	1000	0.1	8.6865	10.2325
200	9000	0.1	0.7061	8.8085	800	1000	0.08	8.6306	10.2383
200	9000	0.09	0.7061	8.8085	800	1000	0.09	8.6306	10.2383
200	9000	0.08	0.7061	8.8085	800	1000	0.1	8.6306	10.2383
300	95000	0.1	0.5380	8.8195	750	1000	0.05	8.6117	10.2404
300	97000	0.1	0.5380	8.8195	750	1000	0.06	8.6117	10.2404
300	99000	0.1	0.5380	8.8195	750	1000	0.07	8.6117	10.2404
350	7000	0.05	1.2875	8.8251	600	1000	0.05	8.5550	10.2467
350	7000	0.06	1.2875	8.8251	600	1000	0.06	8.5550	10.2467
350	7000	0.07	1.2875	8.8251	600	1000	0.07	8.5550	10.2467

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 3000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.1

Number of Support Vectors : 129

Objective Function Value : -1160318858

Training error : 16838657.68613

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 1000 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.05

Number of Support Vectors : 145

Objective Function Value : -667465477

Training error : 40574865.135646

- Kargo Domestik yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.08	2.6919	10.2799	750	1000	0.07	11.03678	7.9701
100	1000	0.1	2.6918	10.2799	750	3000	0.07	11.0368	7.9701
100	3000	0.05	2.6929	10.2799	750	5000	0.07	11.0368	7.9701
99	95000	0.1	2.6707	10.2818	700	95000	0.08	11.2818	8.0622
99	97000	0.1	2.6707	10.2818	700	97000	0.08	11.2818	8.0622
99	99000	0.1	2.6707	10.2818	700	99000	0.08	11.2818	8.0622
97	95000	0.1	2.6262	10.2856	800	1000	0.1	10.7107	8.0640
97	97000	0.1	2.6262	10.2856	800	3000	0.1	10.7107	8.0640
97	99000	0.1	2.6262	10.2856	800	5000	0.1	10.7107	8.0640
96	3000	0.05	2.6037	10.2874	650	95000	0.07	11.5582	8.1561
96	5000	0.05	2.6037	10.2874	650	97000	0.07	11.5582	8.1561
96	7000	0.05	2.6037	10.2874	650	99000	0.07	11.5582	8.1561
95	1000	0.1	2.5814	10.2893	850	1000	0.05	10.5221	8.1579
95	1000	0.07	2.5814	10.2893	850	1000	0.06	10.5037	8.1579
95	3000	0.1	2.5813	10.2893	850	1000	0.07	10.4912	8.1579

> model.optimal

Support Vector Machine object of class "ksvm" > model.optimal

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.08

Number of Support Vectors : 78

Objective Function Value : -5379144
Training error : 8547.714987

SV type: eps-svr (regression)
parameter : epsilon = 750 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.07

Number of Support Vectors : 14

Objective Function Value : -366998.6
Training error : 119828.970056

- Kargo Domestik yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
100	1000	0.1	4.0166	10.0941	400	1000	0.05	8.5381	7.7276
100	1000	0.09	4.0166	10.0941	400	3000	0.05	8.5381	7.7276
100	1000	0.08	4.0166	10.0941	400	5000	0.05	8.5381	7.7276
99	1000	0.07	3.9837	10.0971	350	95000	0.05	8.1833	7.7554
99	1000	0.06	3.9837	10.0971	350	97000	0.05	8.1833	7.7554
99	1000	0.05	3.9837	10.0971	350	99000	0.05	8.1833	7.7554
98	1000	0.05	3.9507	10.1001	450	1000	0.1	8.8612	7.8781
98	1000	0.1	3.9507	10.1001	450	3000	0.1	8.8612	7.8781
98	3000	0.1	3.9006	10.1001	450	5000	0.1	8.8612	7.8781
97	1000	0.07	3.9174	10.1031	300	97000	0.1	7.6793	7.9058
97	1000	0.06	3.9174	10.1031	300	99000	0.09	7.6793	7.9058
97	1000	0.05	3.9174	10.1031	300	99000	0.1	7.6793	7.9058
96	3000	0.1	3.8331	10.1061	500	1000	0.09	9.2336	8.0286
96	5000	0.1	3.8331	10.1061	500	3000	0.09	9.2336	8.0286
96	7000	0.1	3.8331	10.1061	500	5000	0.09	9.2336	8.0286

> model.optimal

Support Vector Machine object of class "ksvm" Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)
parameter : epsilon = 100 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.1

Number of Support Vectors : 98

Objective Function Value : -5352209
Training error : 8733.712864

SV type: eps-svr (regression)
parameter : epsilon = 400 cost C = 1000

Gaussian Radial Basis kernel function.
Hyperparameter : sigma = 0.05

Number of Support Vectors : 25

Objective Function Value : -879940.4
Training error : 53911.046253

- Kargo Internasional yang Dimuat

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
10	1000	0.07	1.6378	15.6945	300	1000	0.05	17.0912	17.4227
10	3000	0.07	1.6378	15.6945	300	1000	0.06	17.0912	17.4227
10	5000	0.07	1.6378	15.6945	300	1000	0.07	17.0912	17.4227
20	95000	0.08	3.1645	15.7759	300	99000	0.08	17.0912	17.4227
20	97000	0.08	3.1645	15.7759	300	99000	0.09	17.0912	17.4227
20	99000	0.08	3.1645	15.7759	300	99000	0.1	17.0912	17.4227
30	1000	0.05	4.5945	15.8572	250	1000	0.05	16.2827	17.4898
30	3000	0.05	4.5945	15.8572	250	1000	0.06	16.2808	17.4898
30	5000	0.05	4.5945	15.8572	250	1000	0.07	16.2793	17.4898
40	95000	0.1	5.8989	15.9386	100	95000	0.08	11.8325	17.5275
40	97000	0.1	5.8989	15.9386	100	97000	0.08	11.8325	17.5275
40	99000	0.1	5.8989	15.9386	100	99000	0.08	11.8325	17.5275
50	1000	0.07	7.0698	16.0200	200	1000	0.05	15.2579	17.5557
50	3000	0.07	7.0698	16.0200	200	1000	0.06	15.2547	17.5557
50	5000	0.07	7.0698	16.0200	200	1000	0.07	15.2524	17.5557

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 10 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.07

Number of Support Vectors : 179

Objective Function Value : -960628.2

Training error : 95.865051

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 300 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.05

Number of Support Vectors : 3

Objective Function Value : -641.9926

Training error : 13470.177918

- Kargo Internasional yang Dibongkar

Metode Grid Search Model TSR-SVR					Metode Grid Search Model ARIMAX-SVR				
Epsilon	C	σ^2	Akurasi Peramalan		Epsilon	C	σ^2	Akurasi Peramalan	
			MAPE	MAPEp				MAPE	MAPEp
21	1000	0.1	3.2460	20.2103	100	5000	0.05	15.0046	16.9309
21	3000	0.1	3.2460	20.2103	100	3000	0.05	14.9869	16.9450
21	5000	0.1	3.2460	20.2103	100	7000	0.05	14.9471	16.9471
22	93000	0.09	3.3873	20.2160	100	1000	0.05	15.0990	16.9541
22	95000	0.09	3.3873	20.2160	100	9000	0.05	14.8750	16.9543
22	97000	0.09	3.3873	20.2160	100	13000	0.05	14.7696	16.9580
22	99000	0.09	3.3873	20.2160	100	11000	0.05	14.8149	16.9581
20	1000	0.06	3.0996	20.2206	100	15000	0.05	14.7322	16.9587
20	3000	0.06	3.0996	20.2206	100	17000	0.05	14.7181	16.9592
19	95000	0.09	2.9593	20.2309	100	19000	0.05	14.6839	16.9623
19	97000	0.09	2.9593	20.2309	100	21000	0.05	14.6926	16.9642
19	99000	0.09	2.9593	20.2309	100	23000	0.05	14.7261	16.9661
24	1000	0.1	3.6689	20.2366	100	25000	0.05	14.7495	16.9694
24	3000	0.1	3.6689	20.2366	100	27000	0.05	14.7297	16.9767
24	5000	0.1	3.6689	20.2366	100	29000	0.05	14.6882	16.9830

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 21 cost C = 1000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.1

Number of Support Vectors : 145

Objective Function Value : -2099181

Training error : 399.483774

> model.optimal

Support Vector Machine object of class "ksvm"

SV type: eps-svr (regression)

parameter : epsilon = 100 cost C = 5000

Gaussian Radial Basis kernel function.

Hyperparameter : sigma = 0.05

Number of Support Vectors : 107

Objective Function Value : -11178919

Training error : 10217.050202

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika Fakultas Matematika, Komputasi, dan Sains Data (FMKSD) ITS :

Nama : Ratna Sulistyowati

NRP : 06211650017006

Program Studi : Magister Statistika / ~~Doktor Ilmu Statistik~~

menyatakan bahwa data yang digunakan dalam Tesis / ~~Disertasi~~ ini merupakan data sekunder yang diambil dari ~~penelitian / buku/ Tugas Akhir/ Thesis/ Disertasi/ publikasi~~ lainnya yaitu:

Sumber : BPS

Keterangan :Buku Indikator Ekonomi (Buletin Statistik Bulanan Januari 2001-September 2017), dan Buku Statistik Transportasi Udara (Tahunan 2001-2017)

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Surabaya, 22 Desember 2017

Mengetahui

Pembimbing Tesis/~~Disertasi~~



Dr. Suhartono, M.Sc

NIP.19710929 199512 1 001

Mahasiswa



Ratna Sulistyowati

*(coret yang tidak perlu)

** Mohon dituliskan data primer apabila datanya dikumpulkan sendiri

BIOGRAFI PENULIS



Penulis dengan nama lengkap Ratna Sulistyowati lahir di Surabaya pada 26 Mei 1985. Penulis merupakan putri ketiga dari tiga bersaudara, pasangan Bapak Alm. Drs. Bambang Judo Soebandono dan Ibu Dra. Hadriani. Penulis menempuh pendidikan formal di SDN Kedung Rejo V Sidoarjo (1991-1997), SLTPN 1 Waru (1997-2000), dan SMUN 15 Surabaya (2000-2003). Selanjutnya, penulis melanjutkan pendidikan di Sekolah Tinggi Ilmu Statistik (STIS) Jakarta (2003-2007) Jurusan Statistik Ekonomi. Setelah menyelesaikan DIV di STIS, penulis bekerja di Badan Pusat Statistik Republik Indonesia (BPS RI) pada Sub Direktorat Konsolidasi Neraca Produksi Nasional (2008-2012). Pada tahun 2010-2011, penulis diberikan ijin belajar studi S1 Manajemen Ekonomi Publik di Sekolah Tinggi Ilmu Administrasi Lembaga Administrasi Negara. Pada tahun 2012, penulis dipindahtugaskan di BPS Provinsi Sulawesi Utara sebagai Fungsional Statistisi Muda. Pada pertengahan tahun 2016, penulis memperoleh kesempatan untuk tugas belajar studi S2 di Departemen Statistika Fakultas Matematika, Komputasi dan Sains Data Institut Teknologi Sepuluh Nopember (ITS). Apabila pembaca ingin memberi kritik, saran serta diskusi lebih lanjut mengenai penelitian ini, dapat menghubungi penulis melalui email ratnasuli@bps.go.id atau amouratna@gmail.com.